

UNIVERSIDAD DE CUENCA
FACULTAD DE INGENIERÍA
ESCUELA DE ELECTRÓNICA Y TELECOMUNICACIONES



**Estimación de modelos estáticos para variables de calidad en el
circuito de molienda de UCEM, planta industrial Guapán**

*Tesis previa a la obtención del título de Ingeniero en Electrónica y
Telecomunicaciones*

Autores:

Christian Eduardo Sánchez Ayora

Noé Marcelo Yungaicela Naula

Director:

Dr. Luis Ismael Minchala Ávila

CUENCA-ECUADOR

Octubre 2015



RESUMEN

La molienda de cemento es la responsable de las características de fineza del producto final, típicamente medido por dos variables de calidad: superficie específica o Blaine (cm^2/g), y el retenido de malla. Una práctica común en plantas de cemento es realizar pruebas de laboratorio de la fineza del cemento cada dos horas, lo que produce un intervalo de dos horas de operación a ciegas con respecto a la calidad del cemento. Como respuesta a esta problemática, en este trabajo se desarrollan modelos de predicción de las variables de calidad, que permiten la minimización de la variabilidad del producto final e incrementan la eficiencia energética. Los modelos implementados son: estadísticos, autorregresivos, neuronales y neurodifusos. Se realiza un análisis estadístico de la base de datos, proporcionada por la empresa UCEM Guapán, correspondiente a las variables de operación y calidad del molino de cemento. Las variables seleccionadas para el desarrollo de los modelos se realizan mediante el tratamiento y análisis de correlación de los datos. Se efectúa la validación en línea con valores de operación en la planta UCEM. Para la selección del mejor modelo utiliza la técnica de error residual. El modelo con mejores resultados es implementado en el software LabVIEW, tanto para la variable del Blaine como para el retenido de malla.

ABSTRACT

2

Cement grinding is the responsible for the fineness characteristics of the final product, typically measured by two quality variables: specific surface or Blaine (cm^2/g), and the percentage passing the sieve No. 325. It is a common practice in cement plants to perform laboratory tests of the fineness of the cement every two hours, leading to a gap of what produces an interval of two hours of blind operation regarding cement quality. As a response to this problematic, in this paper, it will be developed models of prediction of the quality variables, which allows minimization of the final product variable or increased the energy efficiency. The implemented models are: statistics, autoregressive, neuronal, and neuro-fuzzy. A statistical analysis of the database is performed, provided by the UCEM-Guapán factory, corresponding to the operation and quality variables of cement grinding. The selected variables for the development of the models are made through the treatment and analysis of the correlating data. The validation takes place in with operation values in the plants of UCEM. For the selection of the best model, it uses the residual error technique. The model with the best results is implemented in the LabVIEW software, for both the variable of Blaine and for percentage passing the sieve No. 325.



INDICE

RESUMEN.....	1
ABSTRACT.....	2
JUSTIFICACIÓN.....	21
OBJETIVOS.....	23
CAPÍTULO 1: CIRCUITO DE MOLIENDA UCEM, GUAPÁN	25
1.1 INTRODUCCIÓN	25
1.2 PROCESO DE FABRICACIÓN DEL CEMENTO	25
1.3 MOLIENDA DE CEMENTO	27
1.3.1 Secado de puzolana	27
1.3.2 Premolienda	27
1.3.3 Molienda	28
1.4 ESPECIFICACIONES DE FINEZA DE PRODUCTO TERMINADO.....	32
1.5 PROBLEMÁTICA EN EL CONTROL DE CALIDAD DE LA FINEZA.....	32
1.6 PLANTEAMIENTO DE LA SOLUCIÓN.....	33
1.7 ALCANCE DE LA TESIS.....	34
1.8 REVISIÓN BIBLIOGRÁFICA	35
1.8.1 Importancia de la fineza del cemento.....	36
1.8.1.1 Características de fineza del cemento.....	36
1.8.1.2 Distribución de tamaño de las partículas	36
1.8.1.3 Área de superficie específica.....	37
1.8.1.4 Retenido de tamiz de 45 µm	39
1.8.2 Revisión del estado del arte.....	39
1.9 CONTRIBUCIONES DE LA TESIS	40
CAPÍTULO 2: MÉTODOS DE MODELACIÓN	43
2.1 INTRODUCCIÓN	43
2.2 MODELACIÓN ESTADÍSTICA	43
2.2.1 Modelo de regresión lineal múltiple.....	43
2.2.1.1 Técnica de los mínimos cuadrados.....	44
2.2.2 Hipótesis de los modelos de regresión lineal	44
2.2.3 Bondad de ajuste de datos al modelo de regresión lineal	45
2.2.3.1 Coeficiente de correlación lineal simple (r).....	46
2.2.3.2 Coeficiente de correlación múltiple al cuadrado o coeficiente de determinación (r^2).....	47
2.2.3.3 Coeficiente de determinación ajustado ($Adjusted\ r^2$)	48
2.2.3.4 Prueba de significancia individual	49
2.2.3.5 Análisis de varianza y la estadística F	50
2.2.3.6 Análisis de residuos	51
2.2.4 Transformación Box-Cox de la variable dependiente	53
2.2.5 Intervalo de confianza e intervalo de predicción.....	55
2.2.6 Selección de las variables de regresión.....	57
2.2.6.1 Matriz de correlación	58
2.2.6.2 Selección de las variables del modelo mediante el método <i>stepwise</i> o regresión paso a paso.....	59
2.2.7 Capacidad predictiva del modelo	61
2.2.7.1 Estadístico PRESS	61
2.3 MODELACIÓN DINÁMICA	62
2.3.1 Modelo autorregresivo	62
2.3.2 Autocorrelación.....	63
2.3.2.1 Funciones de autocorrelación y autocorrelación parcial	64
2.4 MODELACIÓN NEURONAL	66
2.4.1 Modelos de redes neuronales.....	67

2.4.2	Estructura de la red	68
2.4.3	Tipos de redes neuronales	69
2.4.4	Modelo matemático	69
2.4.5	Entrenamiento de redes neuronales	70
2.4.5.1	Funciones de entrenamiento	71
2.4.5.2	Funciones de activación o transferencia	73
2.5	MODELACIÓN NEURODIFUSA	75
2.5.1	Definición de sistemas neurodifusos	75
2.5.1.1	Sistemas Difusos	75
2.5.2	Clasificación de los sistemas neurodifusos	82
2.5.2.1	Modelos concurrentes	83
2.5.2.2	Modelos cooperativos.....	83
2.5.2.3	Modelos híbridos	83
2.5.3	Modelo ANFIS.	83
2.5.4	Entrenamiento de los sistemas difusos	84

CAPÍTULO 3: MODELACIÓN DE LAS VARIABLES DE CALIDAD 85

3.1	INTRODUCCIÓN	85
3.2	IDENTIFICACIÓN DE VARIABLES DE CALIDAD Y PROCESO	85
3.2.1	Base de datos.....	86
3.2.2	Pre-procesamiento de los datos: Alineación en el tiempo (<i>timestamp</i>) y eliminación de datos atípicos (<i>outliers</i>)	88
3.2.3	Análisis estadístico	89
3.2.4	Pre-selección de las variables de modelación	99
3.3	SELECCIÓN DE LAS VARIABLES DE MODELACIÓN	101
3.3.1	Variables de proceso incluidas por defecto en la modelación	102
3.3.2	Proceso de selección de las variables de modelación	102
3.3.3	Variables de proceso para el modelo del Blaine	103
3.3.4	Variables de proceso para el modelo del retenido de malla No. 324.....	105
3.4	MUESTRAS DISPONIBLES PARA LA MODELACIÓN	106
3.5	IDENTIFICACIÓN Y ESTANDARIZACIÓN DE LAS VARIABLES DE REGRESIÓN	106
3.6	MODELOS ESTADÍSTICOS	107
3.6.1	Proceso de modelación estadística.....	107
3.6.2	Modelos de regresión lineal múltiple de las variables de calidad	108
3.6.2.1	Modelos del Blaine.....	108
3.6.2.2	Modelos del retenido de malla No. 325.....	116
3.7	MODELOS DINÁMICOS	125
3.7.1	Modelos autorregresivos de las variables de calidad	125
3.7.1.1	Modelo autorregresivo del Blaine.....	126
3.7.1.2	Modelo autorregresivo del retenido de malla No. 325.....	129
3.8	MODELOS NEURONALES.....	132
3.8.1	Modelos neuronales de las variables de calidad	132
3.8.1.1	Proceso de entrenamiento para la creación de la red neuronal	132
3.8.1.2	Modelo neuronal del Blaine	134
3.8.1.3	Modelo neuronal de la fineza de malla No. 325	144
3.9	MODELOS NEURODIFUSOS.....	155
3.9.1	Modelos neurodifusos para las variables de calidad	155
3.9.1.1	Proceso de entrenamiento para la creación del modelo neurodifuso.....	156
3.9.1.2	Modelo neurodifuso para el Blaine.....	157
3.9.1.3	Modelo neurodifuso del retenido de malla No. 325	170

CAPÍTULO 4: VALIDACIÓN DE LOS MODELOS DESARROLLADOS 183

4.1	INTRODUCCIÓN	183
4.2	APROBACIÓN DE LOS MODELOS CON NUEVO SET DE DATOS	183
4.2.1	Variables de proceso	184
4.2.2	Aprobación de los modelos estadísticos	186



4.2.2.1	Aprobación del modelo de regresión de segundo orden del Blaine	187
4.2.2.2	Aprobación del modelo de regresión de segundo orden con transformación Box-Cox del Blaine	188
4.2.2.3	Aprobación del modelo de regresión de segundo orden del retenido de malla No. 325	190
4.2.2.4	Aprobación del modelo de regresión de segundo orden con transformación Box-Cox del retenido de malla No. 325.....	192
4.2.3	Aprobación de los modelos dinámicos.....	193
4.2.3.1	Aprobación del modelo autorregresivo del Blaine.....	193
4.2.3.2	Aprobación del modelo autorregresivo del retenido de malla No. 325.....	195
4.2.4	Aprobación de los modelos neuronales	196
4.2.4.1	Aprobación del modelo neuronal del Blaine.....	196
4.2.4.2	Aprobación del modelo neuronal del retenido de malla de 45 μ m	198
4.2.5	Aprobación de los modelos neurodifusos.....	199
4.2.5.1	Aprobación del modelo neurodifuso del Blaine.....	199
4.2.5.2	Aprobación del modelo neurodifuso del retenido de malla de 45 μ m	201
4.3	CORRECCIÓN DE LOS MODELOS.....	202
4.3.1	Corrección de los modelos estadísticos.....	202
4.3.2	Corrección de los modelos dinámicos.....	204
4.3.3	Corrección de los modelos neuronales	206
4.3.4	Corrección de los modelos neurodifusos	208
4.4	SELECCIÓN DE LOS MODELOS DE PREDICCIÓN.....	210
4.4.1	Selección del mejor modelo de predicción para el Blaine	210
4.4.2	Selección del mejor modelo de predicción para el retenido de malla de 45 μ m	212
4.5	RESULTADOS EXPERIMENTALES	214
4.5.1	Resultados experimentales del mejor modelo de predicción para el Blaine ...	216
4.5.2	Resultados experimentales del mejor modelo de predicción para la el retenido de malla de 45 μ m	217
CAPÍTULO 5: CONCLUSIONES.....		219
5.1	LIMITACIONES	219
5.2	CONCLUSIONES	220
5.3	TRABAJO FUTUROS.....	221
REFERENCIAS.....		223

ÍNDICES DE FIGURAS Y TABLAS

FIGURAS

FIGURA 1-1. PROCESO DE FABRICACIÓN DE CEMENTO [3]	27
FIGURA 1-2. PROCESO DE MOLIENDA DE CEMENTO.....	28
FIGURA 1-3. MOLINO DE CEMENTO ("LDFMBALLMILL" HTTPS://COMMONS.WIKIMEDIA.ORG/WIKI/FILE:LDFMBALLMILL.JPG#/MEDIA/FILE:LDFMBALLMILL.JPG)	29
FIGURA 1-4. SEPARADOR CENTRÍFUGO [7]	31
FIGURA 2-1. GRÁFICAS DE NORMALIDAD DEL RESIDUO	52
FIGURA 2-2. GRÁFICA DE RESIDUALES EN FUNCIÓN DE LAS PREDICCIONES	53
FIGURA 2-3. AJUSTE CON TRASFORMACIÓN BOX-COX Y GRÁFICA DE RESIDUOS.....	54
FIGURA 2-4. INTERVALOS DE CONFIANZA Y PREDICCIÓN	57
FIGURA 2-5. GRÁFICA DE LA AUTOCORRELACIÓN MUESTREAL EN FUNCIÓN DEL DESFASE.....	65
FIGURA 2-6. DISEÑO DE LA RED NEURONAL	66
FIGURA 2-7. ESTRUCTURA DEL PERCEPTRÓN MULTICAPA.....	67
FIGURA 2-8. ESTRUCTURA DE LA RED NARX.....	68
FIGURA 2-9. RED NEURONAL CON DOS MATRICES DE PESOS.....	70
FIGURA 2-10. FUNCIÓN DE ACTIVACIÓN LOG-SIGMOIDAL	74
FIGURA 2-11. FUNCIÓN DE ACTIVACIÓN TAN-SIGMOIDAL	74
FIGURA 2-12. FUNCIÓN DE ACTIVACIÓN LINEAL.....	74
FIGURA 2-13. ETAPAS DE LA MODELACIÓN DIFUSA.....	76
FIGURA 2-14. FUNCIÓN DE MEMBRESÍA TRIANGULAR	77
FIGURA 2-15. FUNCIÓN DE MEMBRESÍA TRAPEZOIDAL	77
FIGURA 2-16. FUNCIÓN DE MEMBRESÍA DE CAMPANA GENERALIZADA	78
FIGURA 2-17. FUNCIÓN DE MEMBRESÍA GAUSSIANA	78
FIGURA 2-18. FUNCIÓN DE MEMBRESÍA GAUSSIANA COMBINADA	79
FIGURA 2-19. FUNCIÓN DE MEMBRESÍA EN FORMA DE PI	79
FIGURA 2-20. FUNCIÓN DE MEMBRESÍA DE DIFERENCIA ENTRE DOS FUNCIONES SIGMOIDALES	80
FIGURA 2-21. PRODUCTO DE DOS FUNCIONES DE MEMBRESÍA SIGMOIDALES	80
FIGURA 2-22. OPERADORES LÓGICOS DIFUSOS	81
FIGURA 2-23. MÉTODO DEL CENTROIDE	82
FIGURA 2-24. MÉTODO DEL VALOR MÁXIMO	82
FIGURA 2-25. ARQUITECTURA DEL MODELO ANFIS [49].....	84
FIGURA 3-1. ALINEACIÓN EN EL TIEMPO Y ELIMINACIÓN DE DATOS ATÍPICOS	88
FIGURA 3-2. CURVA DE OPERACIÓN DE LAS VARIABLES DE PROCESO.....	91
FIGURA 3-3. CURVAS DE OPERACIÓN DE LAS VARIABLES DE PROCESO	92
FIGURA 3-4. CURVAS DE OPERACIÓN DE LAS VARIABLES DE PROCESO	93
FIGURA 3-5. CURVA DE OPERACIÓN DE LAS VARIABLES DE PROCESO.....	94
FIGURA 3-6. CURVA DE OPERACIÓN DE LAS VARIABLES DE CALIDAD	94
FIGURA 3-7. GRÁFICAS DE CAPACIDAD DE LAS VARIABLES DE PROCESO	95
FIGURA 3-8. GRÁFICAS DE CAPACIDAD DE LAS VARIABLES DE PROCESO	96
FIGURA 3-9. GRÁFICAS DE CAPACIDAD DE LAS VARIABLES DE PROCESO	97
FIGURA 3-10. GRÁFICAS DE CAPACIDAD DE LAS VARIABLES DE PROCESO	98
FIGURA 3-11. GRÁFICAS DE CAPACIDAD DE LAS VARIABLES DE CALIDAD	98
FIGURA 3-12. VARIABLES DE PROCESO ALTAMENTE CORRELACIONADAS CON EL BLAINE	104
FIGURA 3-13. VARIABLES DE PROCESO ALTAMENTE CORRELACIONADOS CON EL RETENIDO DE MALLA NO. 325	105
FIGURA 3-14. GRÁFICO DE PROBABILIDAD NORMAL Y RESIDUOS TIPIFICADOS DEL MODELO CORTO DEL BLAINE	109
FIGURA 3-15. AJUSTE DEL MODELO CORTO DE REGRESIÓN LINEAL MÚLTIPLE PARA EL BLAINE	110



FIGURA 3-16. GRÁFICO DE PROBABILIDAD NORMAL Y RESIDUOS TIPIFICADOS DEL MODELO LARGO DE SEGUNDO ORDEN DEL BLAINE	112
FIGURA 3-17. AJUSTE DEL MODELO LARGO DE SEGUNDO ORDEN PARA EL BLAINE	112
FIGURA 3-18. GRÁFICO DE PROBABILIDAD NORMAL Y RESIDUOS TIPIFICADOS DEL MODELO BLAINE CON TRANSFORMACIÓN BOX-COX	114
FIGURA 3-19. AJUSTE DEL MODELO CON TRANSFORMACIÓN BOX-COX DEL BLAINE.....	115
FIGURA 3-20. COMPARACIÓN DE LOS MODELOS ESTADÍSTICOS DEL BLAINE.....	116
FIGURA 3-21. GRÁFICO DE PROBABILIDAD NORMAL Y RESIDUOS TIPIFICADOS DEL MODELO CORTO DEL RETENIDO DE MALLA NO. 325	117
FIGURA 3-22. AJUSTE DEL MODELO CORTO DE REGRESIÓN LINEAL MÚLTIPLE PARA EL RETENIDO DE MALLA NO. 325	118
FIGURA 3-23. GRÁFICO DE PROBABILIDAD NORMAL Y RESIDUOS TIPIFICADOS DEL MODELO LARGO DE SEGUNDO ORDEN DEL RETENIDO DE MALLA NO. 325	120
FIGURA 3-24. AJUSTE DEL MODELO LARGO DE SEGUNDO ORDEN PARA LA FINEZA DE RETENIDO DE MALLA 325	121
FIGURA 3-25. GRÁFICO DE PROBABILIDAD NORMAL Y RESIDUOS TIPIFICADOS DE MODELO DEL RETENIDO DE MALLA NO. 325 CON TRANSFORMACIÓN BOX-COX.....	123
FIGURA 3-26. AJUSTE DEL MODELO CON TRANSFORMACIÓN BOX-COX DE LA FINEZA DE RETENIDO DE MALLA 325	123
FIGURA 3-27. COMPARACIÓN DE LOS MODELOS ESTADÍSTICOS DEL RETENIDO DE MALLA NO. 325	124
FIGURA 3-28. CORRELOGRAMA DEL BLAINE	126
FIGURA 3-29. GRÁFICO DE PROBABILIDAD NORMAL Y RESIDUOS TIPIFICADOS DEL MODELO AUTORREGRESIVO DEL BLAINE	127
FIGURA 3-30. AJUSTE DEL MODELO AUTORREGRESIVO DEL BLAINE	128
FIGURA 3-31. CORRELOGRAMA DEL RETENIDO DE MALL NO. 325	129
FIGURA 3-32. GRÁFICO DE PROBABILIDAD NORMAL Y RESIDUOS TIPIFICADOS DEL MODELO AUTORREGRESIVO DEL RETENIDO DE MALLA NO. 325	131
FIGURA 3-33. AJUSTE DEL MODELO AUTORREGRESIVO DEL RETENIDO DE MALLA NO. 325	131
FIGURA 3-34. CREACIÓN DE UNA RED NEURONAL.....	133
FIGURA 3-35. MODELOS DE PREDICCIÓN PARA EL BLAINE PARA LAS FUNCIONES DE ENTRENAMIENTO	136
FIGURA 3-36. HISTOGRAMAS DEL ERROR DE PREDICCIÓN PARA LAS FUNCIONES DE ENTRENAMIENTO	137
FIGURA 3-37. AUTORREGRESIÓN LINEAL DE LA FUNCIÓN DE ENTRENAMIENTO TRAINLM	138
FIGURA 3-38. RED NEURONAL PARA EL MODELO DE PREDICCIÓN PARA EL BLAINE	139
FIGURA 3-39. AUTORREGRESIÓN LINEAL DEL MODELO DE PREDICCIÓN CON 40 NEURONAS	141
FIGURA 3-40. MODELO DE PREDICCIÓN PARA EL BLAINE CON 40 NEURONAS	141
FIGURA 3-41. AUTORREGRESIÓN LINEAL DEL MODELO CON FUNCIÓN DE TRANSFERENCIA TANSIGMOIDAL	143
FIGURA 3-42. MODELO DE PREDICCIÓN CON LA FUNCIÓN DE TRANSFERENCIA TANSIGMOIDAL	144
FIGURA 3-43. MODELOS DE PREDICCIÓN PARA LA FINEZA DE MALLA NO. 325 PARA LAS FUNCIONES DE ENTRENAMIENTO.....	147
FIGURA 3-44. HISTOGRAMAS DEL ERROR DE PREDICCIÓN PARA LAS FUNCIONES DE ENTRENAMIENTO	148
FIGURA 3-45. AUTORREGRESIÓN LINEAL DE LA FUNCIÓN DE ENTRENAMIENTO TRAINLM.	149
FIGURA 3-46. RED NEURONAL PARA EL MODELO DE PREDICCIÓN PARA LA FINEZA DE MALLA NO. 325	150
FIGURA 3-47. AUTORREGRESIÓN LINEAL DEL MODELO DE PREDICCIÓN CON 45 NEURONAS	152
FIGURA 3-48. MODELO DE PREDICCIÓN PARA EL RETENIDO DE MALLA CON 45 NEURONAS.....	152
FIGURA 3-49. AUTORREGRESIÓN LINEAL DEL MODELO CON FUNCIÓN DE TRANSFERENCIA TANSIGMOIDAL	154
FIGURA 3-50. MODELO DE PREDICCIÓN CON LA FUNCIÓN DE TRANSFERENCIA TANSIGMOIDAL	154
FIGURA 3-51. CREACIÓN DEL SISTEMA NEURODIFUSO.....	156
FIGURA 3-52. ESTIMACIÓN DE MODELOS DE PREDICCIÓN EN FASE ENTRENAMIENTO CON 7 VARIABLES.....	159
FIGURA 3-53. HISTOGRAMA DEL ERROR EN LA FASE DE ENTRENAMIENTO CON 7 VARIABLES.....	160
FIGURA 3-54. ESTIMACIÓN DE MODELOS DE PREDICCIÓN EN FASE VALIDACIÓN CON 7 VARIABLES	162
FIGURA 3-55. HISTOGRAMA DEL ERROR EN LA FASE DE VALIDACIÓN CON 7 VARIABLES	163
FIGURA 3-56. ESTIMACIÓN DEL MODELO DE PREDICCIÓN FINAL DEL BLAINE SIN CORRECCIÓN	169
FIGURA 3-57. ARQUITECTURA DEL MODELO NEURODIFUSO DEL BLAINE	170
FIGURA 3-58. ESTIMACIÓN DE MODELOS DE PREDICCIÓN EN FASE ENTRENAMIENTO CON 7 VARIABLES.....	172

FIGURA 3-59. HISTOGRAMA DEL ERROR EN LA FASE DE ENTRENAMIENTO CON 7 VARIABLES.....	173
FIGURA 3-60. ESTIMACIÓN DE MODELOS DE PREDICCIÓN EN FASE VALIDACIÓN CON 7 VARIABLES	175
FIGURA 3-61. HISTOGRAMA DEL ERROR EN LA FASE DE VALIDACIÓN CON 7 VARIABLES	176
FIGURA 3-62. ESTIMACIÓN DEL MODELO DE PREDICCIÓN FINAL DEL RETENIDO DE MALLA SIN CORRECCIÓN	180
FIGURA 3-63. ARQUITECTURA DEL MODELO NEURODIFUSO PARA EL RETENIDO DE MALLA	181
FIGURA 4-1. VARIABLES DE PROCESO PARA LA EVALUACIÓN DEL MODELO DEL BLAINE.....	185
FIGURA 4-2. VARIABLES DE PROCESO PARA LA EVALUACIÓN DEL MODELO DE RETENIDO DE MALLA.....	185
FIGURA 4-3. VALIDACIÓN DEL MODELO DE REGRESIÓN LINEAL MÚLTIPLE DE SEGUNDO ORDEN DEL BLAINE CON CORRECCIÓN DE LA MEDIA Y DESVIACIÓN ESTÁNDAR.....	188
FIGURA 4-4. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO DE SEGUNDO ORDEN DEL BLAINE.....	188
FIGURA 4-5. VALIDACIÓN DEL MODELO DE REGRESIÓN LINEAL MÚLTIPLE CON TRANSFORMACIÓN BOX-COX DEL BLAINE Y CORRECCIÓN DE LA MEDIA Y DESVIACIÓN ESTÁNDAR.....	189
FIGURA 4-6. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO CON TRANSFORMACIÓN BOX-COX DEL BLAINE.....	190
FIGURA 4-7. VALIDACIÓN DEL MODELO DE REGRESIÓN LINEAL MÚLTIPLE DE SEGUNDO ORDEN DEL RETENIDO DE MALLA NO. 325 CON CORRECCIÓN DE LA MEDIA Y DESVIACIÓN ESTÁNDAR	191
FIGURA 4-8. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO DE SEGUNDO ORDEN DEL RETENIDO DE MALLA	191
FIGURA 4-9. VALIDACIÓN DEL MODELO DE REGRESIÓN LINEAL MÚLTIPLE CON TRANSFORMACIÓN BOX-COX DEL RETENIDO DE MALLA NO. 325 Y CORRECCIÓN DE LA MEDIA Y DESVIACIÓN ESTÁNDAR	192
FIGURA 4-10. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO CON TRANSFORMACIÓN BOX-COX DEL RETENIDO DE MALLA	193
FIGURA 4-11. VALIDACIÓN DEL MODELO AUTORREGRESIVO DEL BLAINE CON CORRECCIÓN DE LA MEDIA Y DESVIACIÓN ESTÁNDAR	194
FIGURA 4-12. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO AUTORREGRESIVO DEL BLAINE	194
FIGURA 4-13. VALIDACIÓN DEL MODELO AUTORREGRESIVO DEL RETENIDO DE MALLA NO. 325 CON CORRECCIÓN DE LA MEDIA Y DESVIACIÓN ESTÁNDAR.....	195
FIGURA 4-14. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO AUTORREGRESIVO DEL RETENIDO DE MALLA.....	196
FIGURA 4-15. VALIDACIÓN DEL MODELO NEURONAL DEL BLAINE	197
FIGURA 4-16. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO NEURONAL DEL BLAINE.....	197
FIGURA 4-17. VALIDACIÓN DEL MODELO NEURONAL DEL RETENIDO DE MALLA.....	198
FIGURA 4-18. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO NEURONAL DEL RETENIDO DE MALLA	199
FIGURA 4-19. VALIDACIÓN DEL MODELO NEURODIFUSO DEL BLAINE	200
FIGURA 4-20. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO NEURODIFUSO DEL BLAINE.....	200
FIGURA 4-21. VALIDACIÓN DEL MODELO NEURODIFUSO DEL RETENIDO DE MALLA DE 45 μM	201
FIGURA 4-22. HISTOGRAMA Y GRÁFICO DE PROBABILIDAD NORMAL DEL ERROR DE VALIDACIÓN DEL MODELO NEURODIFUSO DEL RETENIDO DE MALLA	202
FIGURA 4-23. RESPUESTA DEL MODELO CORREGIDO DE REGRESIÓN LINEAL MÚLTIPLE DEL BLAINE.....	203
FIGURA 4-24. RESPUESTA DEL MODELO CORREGIDO DE REGRESIÓN LINEAL MÚLTIPLE DEL RETENIDO DE MALLA NO. 325	204
FIGURA 4-25. RESPUESTA DEL MODELO AUTORREGRESIVO CORREGIDO DEL BLAINE.....	205
FIGURA 4-26. RESPUESTA DEL MODELO CORREGIDO AUTORREGRESIVO DEL RETENIDO DE MALLA NO. 325 ..	206
FIGURA 4-27. CORRECCIÓN DEL MODELO NEURONAL DEL BLAINE	207
FIGURA 4-28. CORRECCIÓN DEL MODELO NEURONAL DE LA FINEZA DE RETENIDO DE MALLA.....	208
FIGURA 4-29. CORRECCIÓN DEL MODELO NEURODIFUSO DEL BLAINE	209
FIGURA 4-30. CORRECCIÓN DEL MODELO NEURODIFUSO DEL RETENIDO DE MALLA DE 45 μM	210
FIGURA 4-31. PREDICCIONES DE LOS MODELOS DEL BLAINE.....	211
FIGURA 4-32. HISTOGRAMAS DE ERROR DE LOS MODELOS DEL BLAINE	212
FIGURA 4-33. PREDICCIONES DE LOS MODELOS DEL RETENIDO DE MALLA DE 45 μM	213



FIGURA 4-34 HISTOGRAMAS DE ERROR DE LOS MODELOS DEL RETENIDO DE MALLA	213
FIGURA 4-35. SOFTWARE DE PREDICCIÓN DE LAS VARIABLES DE CALIDAD	214
FIGURA 4-36. PREDICCIÓN DEL BLAINE CON DATOS DE OPERACIÓN EN LA PLANTA	216
FIGURA 4-37. PREDICCIÓN DEL RETENIDO DE MALLA CON DATOS DE OPERACIÓN EN LA PLANTA.....	217

TABLAS

TABLA 1-1. ESPECIFICACIONES FÍSICAS DE CALIDAD DEL CEMENTO (FUENTE: DEPARTAMENTO DE CONTROL DE CALIDAD DE LA EMPRESA UCEM).	32
TABLA 2-1. TABLA ANOVA DEL MODELO DE REGRESIÓN	51
TABLA 3-1. VARIABLES EXTRAÍDAS DE LA BASE DE DATOS.....	86
TABLA 3-2. VARIABLES DE OPERACIÓN Y CALIDAD	87
TABLA 3-3. RANGO DE VALORES DE LAS VARIABLES DE PROCESO REPRESENTATIVAS.....	89
TABLA 3-4. ESTADÍSTICOS DE LAS VARIABLES DE PROCESO Y CALIDAD	90
TABLA 3-5. VARIABLES DE PROCESO Y CALIDAD NO CONSIDERADAS EN LA MODELACIÓN	100
TABLA 3-6. VARIABLES DE PROCESO Y CALIDAD PRE-SELECCIONADAS.....	100
TABLA 3-7. VARIABLES DE PROCESO INCLUIDAS POR DEFECTO.....	102
TABLA 3-8. VARIABLES DE PROCESO PARA EL MODELO DEL BLAINE	104
TABLA 3-9. VARIABLES DE PROCESO PARA EL MODELO DEL RETENIDO DE MALLA NO. 325.....	106
TABLA 3-10. IDENTIFICACIÓN DE LAS VARIABLES DE REGRESIÓN	107
TABLA 3-11. ANÁLISIS ESTADÍSTICO DE LAS FUNCIONES DE ENTRENAMIENTO	134
TABLA 3-12. ANÁLISIS DE NÚMERO DE NEURONAS DEL MODELO	140
TABLA 3-13. ANÁLISIS DE LAS FUNCIONES DE TRANSFERENCIA DEL MODELO	142
TABLA 3-14. ANÁLISIS ESTADÍSTICO DE LAS FUNCIONES DE ENTRENAMIENTO	145
TABLA 3-15. ANÁLISIS DE NÚMERO DE NEURONAS DEL MODELO	151
TABLA 3-16. ANÁLISIS DE LAS FUNCIONES DE TRANSFERENCIA DEL MODELO	153
TABLA 3-17. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE ENTRENAMIENTO CON 7 VARIABLES	159
TABLA 3-18. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE VALIDACIÓN CON 7 VARIABLES.....	162
TABLA 3-19. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE ENTRENAMIENTO CON 6 VARIABLES	164
TABLA 3-20. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE VALIDACIÓN CON 6 VARIABLES.....	165
TABLA 3-21. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE ENTRENAMIENTO CON 5 VARIABLES	165
TABLA 3-22. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE VALIDACIÓN CON 5 VARIABLES.....	166
TABLA 3-23. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE ENTRENAMIENTO CON 4 VARIABLES	166
TABLA 3-24. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE VALIDACIÓN CON 4 VARIABLES.....	167
TABLA 3-25. COMPARACIÓN DE LAS FUNCIONES DE PERTENENCIA.....	167
TABLA 3-26. COMPARACIÓN DE LOS MODELOS SEGÚN EL NÚMERO DE ITERACIONES	168
TABLA 3-27. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE ENTRENAMIENTO CON 7 VARIABLES	172
TABLA 3-28. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE VALIDACIÓN CON 7 VARIABLES.....	175
TABLA 3-29. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE ENTRENAMIENTO CON 6 VARIABLES	177
TABLA 3-30. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE VALIDACIÓN CON 6 VARIABLES.....	177
TABLA 3-31. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE ENTRENAMIENTO CON 5 VARIABLES	177
TABLA 3-32. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE VALIDACIÓN CON 5 VARIABLES.....	178
TABLA 3-33. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE ENTRENAMIENTO CON 4 VARIABLES	178
TABLA 3-34. ANÁLISIS DE FUNCIONES DE MEMBRESÍA EN FASE VALIDACIÓN CON 4 VARIABLES.....	179
TABLA 3-35. COMPARACIÓN DE LAS FUNCIONES DE PERTENENCIA.....	179
TABLA 3-36. COMPARACIÓN DE LAS FUNCIONES DE PERTENENCIA.....	180
TABLA 4-1. COMPARACIÓN DE LOS MODELOS DEL BLAINE	211
TABLA 4-2. COMPARACIÓN DE LOS MODELOS DEL RETENIDO DE MALLA DE 45 μ M.	214
TABLA 4-3. ANÁLISIS ESTADÍSTICO DEL ERROR DE LOS MODELOS CON DATOS DE OPERACIÓN PARA EL BLAINE	216
TABLA 4-4. ANÁLISIS ESTADÍSTICO DEL ERROR DE LOS MODELOS CON DATOS DE OPERACIÓN PARA EL RETENIDO DE MALLA	218



Universidad de Cuenca
Cláusula de derechos de autor

Yo, Christian Eduardo Sánchez Ayora, autor de la tesis "Estimación de modelos estáticos para variables de calidad en el circuito de molienda de UCEM, planta industrial Guapán", reconozco y acepto el derecho de la Universidad de Cuenca, en base al Art. 5 literal c) de su Reglamento de Propiedad Intelectual, de publicar este trabajo por cualquier medio conocido o por conocer, al ser este requisito para la obtención de mi título de Ingeniero Electrónico y en Telecomunicaciones. El uso que la Universidad de Cuenca hiciere de este trabajo, no implicará afección alguna de mis derechos morales o patrimoniales como autor.

Cuenca, 22 de octubre de 2015

Christian Eduardo Sánchez Ayora
C.I: 0104967864



Universidad de Cuenca
Cláusula de derechos de autor

Yo, Noé Marcelo Yungaicela Naula, autor de la tesis "Estimación de modelos estáticos para variables de calidad en el circuito de molienda de UCEM, planta industrial Guapán", reconozco y acepto el derecho de la Universidad de Cuenca, en base al Art. 5 literal c) de su Reglamento de Propiedad Intelectual, de publicar este trabajo por cualquier medio conocido o por conocer, al ser este requisito para la obtención de mi título de Ingeniero Electrónico y en Telecomunicaciones. El uso que la Universidad de Cuenca hiciere de este trabajo, no implicará afección alguna de mis derechos morales o patrimoniales como autor.

Cuenca, 22 de octubre de 2015

Noé Marcelo Yungaicela Naula
C.I: 0302626205



Universidad de Cuenca
Cláusula de derechos de autor

Yo, Christian Eduardo Sánchez Ayora, autor de la tesis "Estimación de modelos estáticos para variables de calidad en el circuito de molienda de UCEM, planta industrial Guapán", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 22 de octubre de 2015

Firma manuscrita en tinta azul de Christian Eduardo Sánchez Ayora.

Christian Eduardo Sánchez Ayora
C.I: 0104967864



Universidad de Cuenca
Cláusula de derechos de autor

Yo, Noé Marcelo Yungaicela Naula, autor de la tesis "Estimación de modelos estáticos para variables de calidad en el circuito de molienda de UCEM, planta industrial Guapán", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 22 de octubre de 2015

Noé Marcelo Yungaicela Naula
C.I: 0302626205



AGRADECIMIENTOS

La culminación de nuestra etapa académica es, sin duda hoy, la más importante de nuestra vida. No lo hubiéramos logrado sin la ayuda y apoyo de excelentes personas. Por esta razón es un gusto extenderles nuestros agradecimientos:

A Dios que nos ha brindado la vida y la compañía de nuestros seres queridos.

De manera especial a nuestros padres y hermanos que nos han acompañado durante todo el trayecto de nuestra preparación con su esfuerzo y comprensión.

Al Dr. Ismael Minchala por su acertada dirección y orientación para la culminación de este trabajo.

A los directivos y trabajadores de la planta industrial UCEM Guapán, por la información y facilidades brindadas para realizar este trabajo.

Y a cada una de las personas que han estado junto a nosotros a lo largo de estos años, amigos, compañeros y profesores.

Christian y Marcelo



DEDICATORIA

Este trabajo va dedicado en primer lugar a Dios, ya que sin su voluntad nada hubiese sido posible. A mis padres: Eduardo y Martha, con quienes juntos hemos conseguido cumplir esta meta, no se trata de un logro individual sino de toda nuestra familia. Además a mis hermanas: Gabriela, Vanessa y Valentina.

Christian



DEDICATORIA

Dedico este trabajo a mi familia. A mis padres: José e Hilda por su apoyo incondicional y constante para alcanzar mis metas. A mis hermanos: Ofelia, Francisco y Tania con quienes he compartido los más gratos momentos de mi vida.

Marcelo



JUSTIFICACIÓN

La industria del cemento busca continuamente aumentar los beneficios y márgenes de ganancia, garantizando al mismo tiempo el uso de los recursos naturales de forma sostenible. Esto supone el desarrollo e implementación de nuevas estrategias en la operación y control de los procesos involucrados en la manufactura del cemento.

La compañía “UNIÓN CEMENTERA NACIONAL, UCEM C.E.M.” localizada en Guapán (Provincia del Cañar) comercializa su producto en las provincias de: Azuay, Cañar, Loja, Zamora Chinchipe y Morona Santiago. El cemento Portland Puzolánico que produce mantiene la certificación de calidad establecida en la norma NTE INEN 490:2011.

El mayor consumo energético en la producción de cemento se localiza en el proceso final de molienda. Para mantener las características de calidad del producto bajo estándares internacionales, la empresa mantiene un control permanente de las operaciones de cada área de producción.

La operación del molino de cemento de la planta industrial Guapán se realiza desde el panel de control central, en donde panelistas por turnos rotativos operan las consignas de los controladores distribuidos del proceso. Sus decisiones se basan en la experiencia adquirida e información transferida entre el personal que opera la planta.

Por tales motivos, en este trabajo se plantea el desarrollo de herramientas de predicción, basadas en modelos matemáticos, de los indicadores de la fineza del cemento: Blaine y retenido de tamiz de 45 μm . El objetivo es proporcionar a los operadores y panelistas un instrumento de apoyo en la decisión de operación correcta y bien fundamentada de la planta de cemento.



OBJETIVOS

GENERAL

23

Modelar las variables de calidad de cemento, fineza de retenido en malla y Blaine, utilizando datos de operación del circuito de molino de cemento de UCEM, planta industrial Guapán.

ESPECÍFICOS

1. Estudiar el proceso de molienda de la planta industrial Guapán.
2. Determinar las variables de interés, a través de análisis estadísticos.
3. Generar diferentes modelos para predecir el comportamiento de las variables de calidad para tomar decisiones de corrección en la operación de la planta.
4. Validar, probar y refinar los modelos obtenidos.
5. Implementar un software de predicción de las variables de calidad en la planta industrial Guapán.



CAPÍTULO 1: CIRCUITO DE MOLIENDA UCEM, GUAPÁN

1.1 Introducción

La compañía “UNIÓN CEMENTERA NACIONAL, UCEM C.E.M.” localizada en Guapán (Provincia del Cañar) es una de las mayores proveedoras de cemento en el país, con una producción que bordea las 800.000 toneladas métricas por año. Su producción permite abastecer la demanda de las principales ciudades y poblaciones de las provincias de Cañar, Azuay, Loja, Zamora Chinchipe y Morona Santiago.

El producto que comercializa la compañía UCEM es el Cemento Portland Puzolánico Tipo IP- saco de 50 kg y tonelada a granel. El producto mantiene la certificación de conformidad con el sello de calidad de acuerdo a la norma NTE INEN 490:2011.

Para la fabricación del cemento, la empresa UCEM dispone de áreas secuenciales de procesamiento del producto, estratégicamente ubicadas y que cumplen funciones fundamentales.

El cemento Portland Puzolánico cumple la norma ASTM C 150 [2], donde se indican las características físicas y químicas que debe cumplir el producto. Este trabajo propone herramientas de software para predicción de las características físicas de fineza; Blaine y retenido de malla de 45 μ m.

1.2 Proceso de fabricación del cemento

La secuencia de fabricación del cemento se cumple en las siguientes áreas de producción: Trituración, prehomogenización, molienda de crudo, homogenización, clinkerización, molienda de clinker y despacho [1].

En el área de trituración, se disminuye la materia prima (caliza) procedentes de las canteras desde un tamaño aproximado de 1,20 m hasta un retenido de 5% en la malla de 25 mm.

El área de prehomogenización cumple dos objetivos: almacenar el material proveniente del área de trituración y realizar una mezcla de las materias primas.

El objetivo del área de molienda de crudo es dosificar y preparar la materia prima de acuerdo a los requerimientos físicos-químicos para la elaboración del clinker de cemento. El equipo principal de esta área es el molino giratorio de bolas. Adicionalmente en esta área se logra evaporar el contenido de agua en la materia prima utilizando los gases provenientes de la torre de precalentador del horno rotativo.

El área de homogenización tiene por objeto mezclar la harina cruda para mejorar la homogeneidad del material. Esto se realiza mediante la inyección de aire comprimido a impulsos para generar un movimiento interno del polvo. El material saliente, luego de pasar las pruebas de calidad, se traslada a los silos de almacenamiento y está listo para ingresar al horno. La dosificación del material que ingresa al horno se controla desde el panel central.

El área de clinkerización y enfriamiento es fundamental en el proceso de fabricación de cemento. La formación del clinker requiere que el material crudo pase por el precalentador, el horno rotatorio y el enfriador. El material crudo circula por el precalentador hasta llegar al horno rotatorio que alcanza una temperatura de 1540 °C dando lugar a un nuevo compuesto denominado clinker de cemento. Finalmente el clinker pasa por el proceso de enfriamiento, en donde la transferencia de temperatura se realiza por la inyección de aire frío mediante ventiladores.

El paso final en el proceso de manufactura del cemento consiste en la transformación del clinker en polvo de cemento. Un molino rotatorio con bolas de acero se utiliza para este propósito. El circuito de molino de cemento está compuesto por un molino de bolas y un separador. El molino de bolas tritura el material que ingresa a éste, para convertirlo en polvo de cemento. El separador de aire clasifica el producto de acuerdo a los requerimientos establecidos por el departamento de calidad.

El cemento terminado es almacenado en silos. El despacho se realiza mediante embolsadoras (cada bolsa de 50kg), o a granel. La Figura 1-1 muestra el proceso de fabricación del cemento.

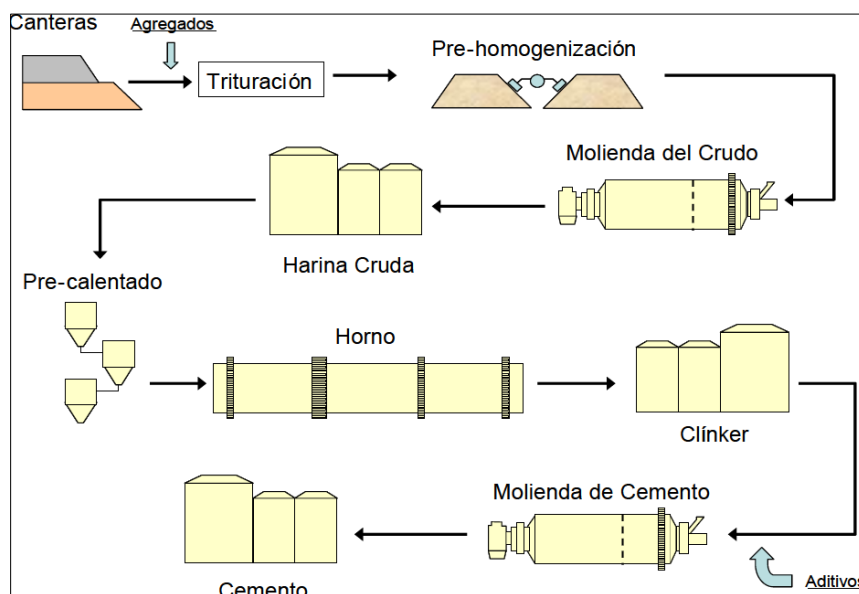


Figura 1-1. Proceso de fabricación de cemento [3]

1.3 Molienda de cemento

Esta área de producción es conocida, en la compañía UCEM, como el área G. Dentro de esta área se distinguen tres sistemas: el secado de puzolana, la premolienda y la molienda.

1.3.1 Secado de puzolana

El secado de puzolana se realiza mediante la generación de aire caliente quemando crudo reducido de petróleo, para obtener una humedad relativa del 4%. En la alimentación existe una criba que separa materiales superiores a 50 mm de diámetro.

1.3.2 Premolienda

En este sistema se dosifica y mezcla los componentes del cemento: clinker (70%), puzolana seca (23%), caliza (3% máximo) y yeso (3.5% máximo). El material resultante pasa a través de dos cribas vibratorias, y el material grueso es realimentado al triturador de impacto.

El equipo principal es un triturador de impacto de eje vertical, que reduce el tamaño de las partículas de 25 mm a 6 mm. También se tiene un equipo clasificador que genera tres productos: el material menor a 6mm que es dirigida hacia la etapa de molienda, el material entre 6 y 50 mm que retorna a la línea de trituración y el material de rechazo mayor a 50 mm que es enviado a una chancadora para su retorno al sistema.

1.3.3 Molienda

El proceso final de la fabricación de cemento es la molienda del cemento. Los componentes principales de esta área son: El molino de bolas y el separador centrífugo.

La Figura 1-2 muestra el proceso de molienda de cemento y los elementos involucrados.

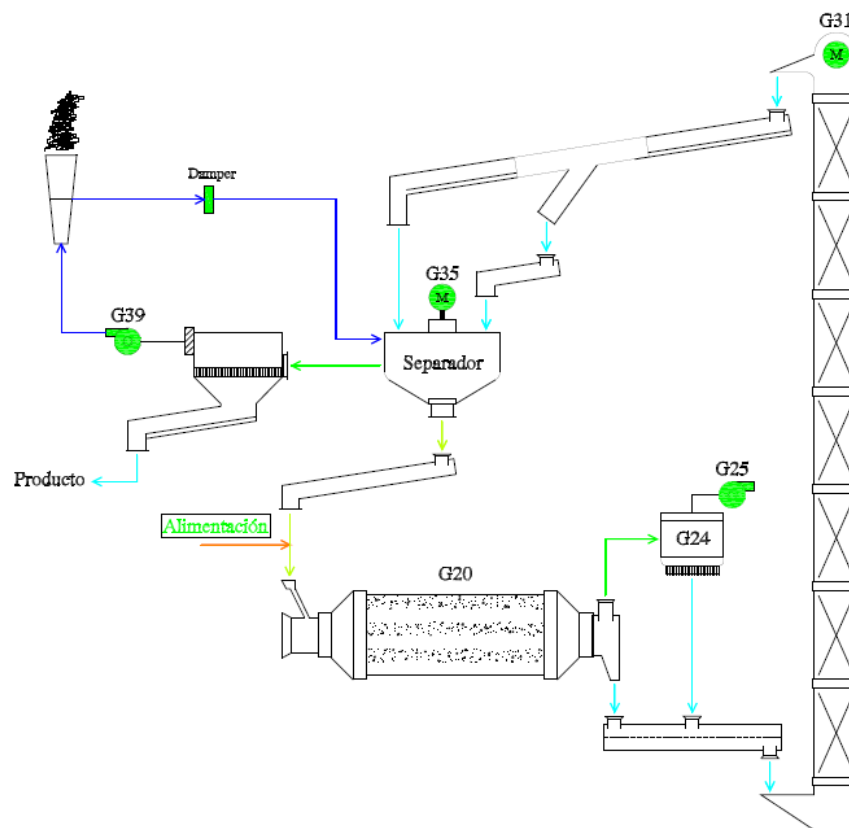


Figura 1-2. Proceso de molienda de cemento

Los elementos identificados en el proceso de molienda de cemento (Figura 1-2) son: G20 es el molino de cemento, G24 es colector de polvo del molino, G31 es el elevador de cangilones, G35 es el separador centrífugo y G39 es colector de polvo del separador. Las flechas indican el flujo del material a través del área G.

El proceso de molienda de cemento inicia con la alimentación al molino de cemento. El material que ingresa al molino incluye aquella proveniente de la etapa de premolienda, además de la puzolana seca y el material que retorna del separador centrífugo.

El molino de bolas, utilizado en la molienda del clinker, tiene un diámetro de 3,66 m y una longitud total de 11,28 m, es de tipo horizontal dividido en dos cámaras, la primera de 3,66 m de longitud en la que se realiza la molienda gruesa y la segunda de 7,62 m en la que se realiza la molienda fina [1]. En la Figura 1-3 se muestra el esquema del molino descrito.

El clinker ingresa al primer compartimento, el cual contiene bolas de acero (de 30 mm a 90 mm) que caen dentro del molino aplicando fuerza de impacto y fricción a las partículas de clinker. Cuando el material alcanza una fineza determinada y es capaz de pasar a través de un diafragma intermedio, es conducida al segundo compartimento mediante un barrido de aire que ingresa paralelo al eje horizontal del molino.




Figura 1-3. Molino de cemento ("LDFM Ball Mill")

https://commons.wikimedia.org/wiki/File:LDFM_Ball_Mill.jpg#/media/File:LDFM_Ball_Mill.jpg

El segundo compartimento posee bolas de acero más pequeñas (de 15 a 25 mm) que el primer compartimento; a la salida del segundo compartimento se obtiene el cemento fino que será conducido al proceso de clasificación. La extracción del material del segundo compartimento se realiza a través de un flujo de aire como se observa en la Figura 1-3.

El flujo de material entrante es regulado desde el panel de control. El grado de llenado de las cámaras o compartimentos son sensados durante el funcionamiento mediante los micrófonos que están instalados cerca de cada compartimiento. A pesar del ruido general que acompaña el proceso de molienda, estos micrófonos sensibles son capaces de recoger los cambios en el sonido del molino. Un molino vacío producirá un sonido más fuerte, mientras que para mayores cantidades de clínker, se amortigua el ruido metálico provocado por los medios de trituración resultando en valores de decibeles más bajos. Los resultados de los sensores son expresados en grado de llenado de las cámaras (%) y guardados en una base de datos.

Es indispensable mantener un control del grado de llenado de los compartimentos con el fin de obtener la mayor eficiencia energética en el proceso de molienda [4].

La consigna de velocidad de giro del molino es uno de los criterios más importantes a considerarse en su operación. De acuerdo a estudios presentados en [4],[5] y [6] la velocidad operativa del molino es el 75% de la velocidad crítica del molino.

El molino de la planta UCEM cuenta con sensores de: corriente del motor, temperatura de los piñones y cojinetes, temperatura de los devanados del motor y temperatura de la salida del material, cuyos valores son guardados en una base de datos.

El material que abandona el molino, se conduce al separador a través del elevador de cangilones. El motor que opera el elevador, identificado con G31 (Figura 1-2), tiene sensores de velocidad y consumo de corriente, que proporcionan información útil del funcionamiento del circuito de molienda.

31

El separador clasifica las partículas de acuerdo a su tamaño. La UCEM dispone de un separador centrífugo como la que se muestra en la Figura 1-4.




Figura 1-4. Separador centrífugo [7]

El separador cuenta con un ventilador externo (Figura 1-4) que toma el aire entrante a la carcasa del separador a través de una o más entradas; se hace girar las paletas en la misma dirección que el rotor giratorio. El aire ingresa uniformemente distribuido debido al cuidadoso diseño de las entradas de aire y paletas de guía. El rotor amplifica la velocidad del aire, el cual viaja a través de la zona de separación, recoge el material fino y sale desde el centro del rotor. El conducto de salida extrae el aire junto al material fino en la parte superior del separador [7].

En la parte inferior del separador está la salida del material grueso. Este material regresa al molino de cemento cerrando, de esta forma, el circuito de molienda de cemento.

El rotor, identificado como G35 (Figura 1-2), es controlado desde el panel central, siendo posible consignarle la velocidad requerida. Esta consigna es determinante en las características de calidad de fineza del cemento.

El motor del colector de polvo del separador, identificado como G39 (Figura 1-2), absorbe las partículas de menor tamaño y las envía hacia los silos de almacenamiento de producto terminado. Su velocidad es consignada desde el panel de control, y almacenada en una base de datos.

Adicionalmente, se dispone de un sensor que mide el retorno del material.

Resulta evidente que, si se desea modelar el comportamiento de las características físicas del cemento, como variables indispensables deben considerarse los que intervienen en el proceso de molienda del cemento (área G).

1.4 Especificaciones de fineza de producto terminado

Las especificaciones de fineza del cemento (según los requisitos internos), elaborado en la compañía UCEM, se muestran en la Tabla 1-1.

Tabla 1-1. Especificaciones físicas de calidad del cemento (Fuente: Departamento de control de calidad de la empresa UCEM).

Parámetro	Unidad	Máx.	Mín.
Blaine	cm ² /g	4500	3800
Retenido de tamiz de 45 µm	%	5	2.5

La determinación la fineza mediante el tamiz de 45 µm (No. 325) se realiza de acuerdo a Norma Técnica Ecuatoriana NTE INEN 957 [8] y la determinación de la fineza mediante el aparato de permeabilidad al aire de acuerdo a la Norma Técnica Ecuatoriana NTE INEN 196 [9].

1.5 Problemática en el control de calidad de la fineza

En el control de calidad, las cualidades físicas del cemento son las que efectiva y predominantemente determinan la calidad del cemento producido.

En el caso de estudio del presente trabajo, el Blaine y el retenido de malla No. 325 representan cualidades de fineza del cemento.



En la compañía UCEM, la caracterización del cemento mediante los indicadores de fineza se ve restringida a un muestreo que se realiza cada dos horas. En el tiempo entre estos intervalos (dos horas), los operadores y panelistas desconocen si el cemento es producido bajo los requisitos definidos por la misma empresa, pudiendo actuar únicamente al final de estos intervalos. Esto obliga a los panelistas a establecer la operación del circuito de molino de modo que los parámetros de fineza (Blaine y retenido de tamiz de 45 μm) se establezcan sobre los valores estándares. Indudablemente esto genera gastos innecesarios de energía, además de la posibilidad de que en ciertos instantes del periodo comprendido entre las dos horas de muestreo se obtenga una calidad del producto por debajo del estándar.

Un inconveniente adicional es que a pesar de son conocidos entre los operadores del molino ciertos criterios de operación para la mejora de la producción y control de las variables de calidad del cemento, no se disponen de bases de estudio que respalden dicha toma de decisiones. Incluso existen algunas diferencias de criterios de cada trabajador durante la operación del molino de cemento a la hora de seleccionar los valores de las variables de operación; generalmente se toman decisiones de cambio o conservación de los valores de consigna de las variables de operación del molino de cemento en base a resultados empíricos obtenidos en operaciones pasadas. Esto significa un gran problema al momento de establecer nuevos parámetros de operación cuando se genera una perturbación en la planta, incluso si únicamente se varían parámetros que en cierto momento no son controlables por ejemplo, la alimentación de puzolana, o la alimentación del clinker.

1.6 Planteamiento de la solución

La solución que se desarrolla en este trabajo es modelar las variables de calidad de fineza del cemento; Blaine y retenido de tamiz de 45 μm .

El objetivo es estudiar cuatro modelos de predicción: modelos estadísticos, modelos dinámicos, modelos neuronales y modelos neurodifusos. De los modelos obtenidos comparar los resultados y establecer el mejor modelo predictivo, para su posterior implementación en la planta UCEM.

Para la modelación, se dispone de la base de datos provista por el departamento de investigación y desarrollo de la empresa UCEM que contiene información de las variables capturado por los operadores/panelistas entre el 01/04/2014 hasta el 30/04/2015. El periodo de muestreo de las variables de proceso es de una hora, y el de las variables de calidad de dos horas.

Adicionalmente el circuito de molienda cuenta con un sistema SCADA (Supervisory Control And Data Adquisition), que recolecta todas las señales provenientes de los sensores del proceso de molienda. Las señales recibidas son guardadas en una base de datos. Para el presente trabajo, los datos disponibles de la base de datos de este sistema son del mes de enero del 2015.

Los modelos predictivos permitirán obtener una aproximación de las características de fineza del cemento entre el periodo que se realiza el control de calidad (dos horas).

El desarrollo de los modelos se realizará utilizando la herramienta de programación *MATLAB*.

1.7 Alcance de la Tesis

El presente trabajo ayudará en la toma de decisiones en la operación de la planta de cemento. El mejor modelo predictivo será implementado en el software LabVIEW, y luego de su validación en la planta UCEM se dispondrá para su uso en el área de control.

El mayor beneficio de disponer de modelos predictivos de las variables de fineza es la posibilidad de operar con menor variabilidad el proceso de molienda y en consecuencia, obtener un producto con menor variabilidad en su calidad.



Un beneficio adicional es el ahorro de energía. La energía eléctrica que se consume en la producción de cemento es de aproximadamente 110 kWh/tonelada, de los cuales un 30% es utilizado en el proceso de triturado y molienda de la materia prima, mientras que cerca del 40% de esta energía es utilizado en el proceso de molienda del clinker a polvo de cemento [10] y el otro 30% se distribuye en los otros procesos de manufactura del cemento.

La problemática de alimentar correctamente el molino de cemento ha sido objetivo de variados estudios [11][12], principalmente porque en el caso extremo de alimentar con poco material el molino produce un ineficiente uso de las bolas giratorias, al igual que fricción entre ellas y desgaste energético innecesario. Por otro lado, una carga excesiva podría incluso producir taponamientos.

Un análisis estadístico de las variables de proceso y calidad del circuito de molienda de cemento permitirá estandarizar criterios de operación entre panelistas, obteniendo consecuentemente una correcta operación y control de esta etapa de la manufactura; generando eficiencia en la planta, minimizando el consumo de energía eléctrica y entregando un producto final dentro de las especificaciones de calidad internacionales.

En resumen, lo que el presente trabajo permitirá es mejorar el circuito de molino de cemento, con propósitos de generar eficiencia energética y una operación más estable, *i.e.* estandarizar criterios de operación entre panelistas, optimizar la producción y mantener una calidad de producto con menor variabilidad.

1.8 REVISIÓN BIBLIOGRÁFICA

En esta sección se estudia la importancia de la fineza del cemento, incluyendo el análisis de la distribución del tamaño de las partículas. Además se revisa el estado del arte de la modelación de circuitos de molienda.

1.8.1 Importancia de la fineza del cemento

Para determinar las relaciones entre la fineza de las partículas de cemento y los efectos en el rendimiento de la masa del cemento como cinética de hidratación, tiempo de fraguado, entre otras, es necesario asignar valores numéricos a las características de la fineza. Esta asignación debe ser de forma clara, única, bien definida y que sea medible en la práctica [7].

Las características de fineza llegan a ser más importantes a medida que las partículas tienden a ser más pequeñas. El comportamiento del cemento será dependiente de las propiedades individuales de estas partículas.

1.8.1.1 Características de fineza del cemento

Principalmente, la característica de la partícula es su tamaño, que puede ser representado como una dimensión lineal, un área superficial, un volumen o una masa [4].

En general, la característica de tamaño del cemento puede ser representada por una distribución expresada como funciones de valores discretos o continuos en ya sea formas incrementales o acumulativas. La distribución de las partículas intrínsecamente es una variable continua, de modo que sus datos son clasificados apropiadamente en intervalos discretos.

1.8.1.2 Distribución de tamaño de las partículas

La forma más común de obtener la distribución del tamaño de las partículas (PSD), es realizando un análisis de tamiz seco. Los tamices son colocados en pila, de modo que el tamiz con malla de apertura más grande es colocado en la parte superior y la de malla más pequeña en la parte inferior seguido por un recipiente.



La muestra del material que se pretende caracterizar es colocada en el tamiz superior, y el conjunto de tamices se hace vibrar mecánicamente por un periodo de tiempo definido. La masa de material retenido en cada tamiz es medida y convertida en un porcentaje del total de la masa de la muestra analizada. Inevitablemente existirán pérdidas de material debido a la adherencia del mismo en la superficie de los tamices y entre las aperturas de los tamices. Según [4] estas pérdidas no deben superar el 1% del total de la muestra.

La representación del PSD puede ser en forma de tabla, gráfico o matemático.

Varias propuestas de funciones paramétricas se han definido para la representación del PSD [13]. En [14] se reporta que la función de distribución de Rosin-Rammler (RR) es la más usada en la industria del cemento. Las razones, que se indican en [13], son que la distribución RR provee una buena aproximación de los datos de distribución de los tamaños de las partículas, además de que logra la mejor representación de la falta de simetría de la PSD del cemento.

Las formas más convencionales de estimar la fineza del cemento es determinar:

- El área de superficie específico, y
- El porcentaje de material que pasa a través del conjunto de tamices.

Estas pruebas son los dos procedimientos más comunes de control de fineza que se realizan cada 2-4 horas en la mayoría de plantas de cemento [14].

1.8.1.3 Área de superficie específica

El área de superficie específica es una medida acumulativa de fineza del cemento, y está expresado en centímetros cuadrados del área de superficie total por gramo, o en metros cuadrados del área total por kilogramo del material [7].

(1-1)

$$\text{Área de superficie específica} = S/M$$

donde,

S – es el área de superficie total de todas las partículas en la muestra, m^2

M – es la masa total de la muestra, kg

38

El área de superficie específico puede ser determinado mediante dos métodos establecidos según el estándar ASTM:

1. Prueba del turbidímetro de Wagner (ASTM C 115 [15]), y
2. Prueba de permeabilidad del aire de Blaine (ASTM C 204 [16]).

La prueba de Blaine de finura es la que más ampliamente se utiliza en la industria para la medición del área de superficie específico del cemento portland. Esta prueba se basa en la evaluación de la tasa de flujo de aire a través de un lecho compactado de cemento. El equipo de prueba Blaine se compone fundamentalmente de un dispositivo para extraer una cierta cantidad de aire a través de un lecho de cemento compactado hasta cierta porosidad. El número y tamaño de los poros en el lecho de cemento preparado determina la tasa de flujo de aire a través del lecho, que, a su vez, define el tamaño de las partículas de cemento (ASTM C 204 [16]).

Según [17], la prueba de permeabilidad del aire de Blaine tiende a ser poco reproducible, ya que además de los errores de configuración del dispositivo y la realización del procedimiento, está el factor humano inducido por los cambios de turno diarias en la fábrica de cemento lo que contribuirá a mediciones inconsistentes. Los autores recomiendan mediciones repetitivas del Blaine y ajustar el proceso de molienda solo si se producen cambios significantes en este indicador.



El Blaine es una característica integral de la fineza del cemento, sin embargo con un solo indicador no es posible representar efectivamente toda distribución del tamaño de las partículas (PSD) del cemento. De hecho, es posible tener muestras con distintos PSD pero con el mismo Blaine [18]. Esto representa un obstáculo, debido a que como se explicó anteriormente, las características de rendimiento del cemento son explicadas efectivamente por la proporción de las partículas finas y gruesas encontradas en el material (forma del PSD del cemento).

1.8.1.4 Retenido de tamiz de 45 μm

La norma ASTM C 430 [2], establece la metodología para la determinación de la fineza del cemento con el uso del tamiz de 45 μm (No. 325).

Un gramo de cemento se coloca primero en un tamiz, seco y limpio, de 45 μm y se moja completamente con un chorro suave de agua. Luego, la boquilla de pulverización se ajusta para producir una cierta presión, y el tamiz que contiene la muestra se lava con el chorro de agua en un movimiento circular durante 1 minuto. Después de esto, el tamiz y el residuo se secan en un horno o sobre una placa caliente. El residuo se toma del tamiz, se pesa, y el porcentaje del material que pasa el tamiz de 45 μm (No. 325) se informa como resultado.

La cantidad del material por debajo de 45 micras también se puede estimar utilizando la PSD acumulativa de la muestra de cemento. Sin embargo, esta estimación puede ser ligeramente diferente de la del resultado de la prueba ASTM C 430 [2] debido a las diferencias en los principios subyacentes a las dos técnicas de medición (para la determinación del PSD se utiliza un tamiz seco).

1.8.2 Revisión del estado del arte

El molino de cemento es el equipo que más energía consume. Por ello los estudios se han enfocado en desarrollar modelos tanto estáticos como dinámicos de este proceso fundamental en la manufactura del cemento.

El objetivo, sin duda, es lograr la mayor eficiencia energética. En [19] se desarrollan modelos de regresión, basados en redes neuronales, para estimar el consumo de energía del molino de cemento tomando como variables de entrada la alimentación de la materia prima, la producción total y tiempo de trabajo diario. El modelo obtenido se utiliza para predecir el consumo de la electricidad en el accionamiento principal de los molinos y para evaluar el comportamiento de los índices de consumo establecido.

En [20] se desarrolla una simulación del Blaine y retenido de tamiz de 45 μm , utilizando modelos de curvas estáticas. Únicamente se cuenta con dos variables en las ecuaciones de los modelos: La velocidad del motor del ventilador G39 y la velocidad del motor del separador G35 (Figura 1-2), debido a que se considera que estas variables están directamente correlacionadas con la cantidad de material de retorno y alimentación del molino de cemento y éstas a su vez con la fineza del cemento.

En [21], [22] se presentan modelos de regresión y análisis estadísticos de circuitos de molienda cuyos criterios serán considerados para el presente trabajo.

1.9 CONTRIBUCIONES DE LA TESIS

El trabajo presentado en este documento generó:

- Metodologías para el diseño y comparación de los siguientes modelos de estimación de la fineza del cemento: estadísticos, autorregresivos, neuronales y neurodifusos.
- Metodologías para el procesamiento, análisis estadístico y tratamiento de datos de operación.
- Un software de predicción de las variables de calidad: Blaine y retenido de malla para el circuito de molienda de la planta de cemento UCEM.



- La creación de los artículos: “A comparative study of black-box models for cement quality prediction using input-output measurements of a closed circuit grinding” y “Estudio comparativo de modelos de caja-negra para la predicción de la calidad de cemento usando medidas de entrada y salida de un circuito de molino cerrado”. Los artículos han sido enviados al *10th anual IEEE International Systems Conference* y a la revista IEEE Latinoamérica.



CAPÍTULO 2: MÉTODOS DE MODELACIÓN

2.1 Introducción

43

Este capítulo presenta el desarrollo teórico de los métodos de modelación que se implementarán a lo largo de este trabajo. Los modelos que se analizan son: estadístico, dinámico, neuronal y neurodifuso.

2.2 Modelación estadística

Esta sección presenta la técnica de regresión lineal múltiple. Este método permite especificar, estimar e interpretar un modelo explicativo en que una variable dependiente se analiza en función de una o unas variables explicativas. El propósito es de cuantificar la relación entre la variable dependiente y las variables independientes, estableciendo con qué intervalo de confianza las estimaciones cuantitativas se ajustan a la realidad de la población que se estudia [23]. Además se establecen estadísticos de bondad de ajuste de los modelos regresivos múltiples que se plantean.

2.2.1 Modelo de regresión lineal múltiple

El modelo regresivo lineal se representa por:

$$\mu_{Y|X} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + U \quad (2-1)$$

donde $\mu_{Y|X}$ es la media poblacional de la variable independiente modelada, X son las variables independientes llamadas variables de regresión, β_k son los coeficientes de regresión y U es el error de predicción.

El error de predicción U incluye cuatro términos no cuantificables: los comportamientos puramente aleatorios, el efecto de variables independientes que debieron ser incluidos en el modelo, la imperfección en el muestreo de las variables independientes y los errores derivados de la selección de los modelos [23].

Los parámetros aleatorios β se desean estimar de forma que el modelo se ajuste de la mejor manera sobre la información recopilada. La técnica más utilizada para la estimación de los coeficientes de regresión es la técnica de los mínimos cuadrados.

2.2.1.1 Técnica de los mínimos cuadrados

Mediante esta técnica se determinan los coeficientes β minimizando los errores de predicción.

Sobre la base de las observaciones obtenidas para X y Y , que son variables aleatorias, se suponen constantes sobre N muestras recopiladas (siendo N el universo de muestras), de modo que pueda plantearse un modelo de la forma siguiente:

$$Y = b_0 + b_1X_1 + b_2X_2 + b_3X_3 + \cdots + b_kX_k + e \quad (2-2)$$

dado que los parámetros β ahora se suponen términos constantes b , y el término de error, e , también se supone constante para cada observación.

En [24] se presenta la técnica de los mínimos cuadrados para determinar los coeficientes b . En esencia, el procedimiento consiste en minimizar la suma de los errores cuadráticos con el uso de derivadas parciales, para obtener un conjunto de ecuaciones de las cuáles resultan las soluciones para los coeficientes b .

2.2.2 Hipótesis de los modelos de regresión lineal

Las suposiciones del modelo de regresión lineal múltiple según [25] son:



- i). La variable dependiente Y y las variables independientes X siguen una distribución normal;
- ii). Existe un número suficiente de observaciones para estimar los coeficientes de regresión β_j con $j = 1, \dots, k$; es decir, si existen k variables independientes con N muestras cada variable, entonces se requiere $k < N$;
- iii). Las relaciones entre las variables de regresión y la variable dependiente es lineal;
- iv). Inexistencia de multicolinealidad entre las variables de regresión X . Esto significa que las variables independientes son linealmente independientes;
- v). El error de predicción sigue una distribución normal con media cero y varianza σ^2 ;
- vi). El error de predicción no es auto-correlacionado, es decir que sus valores actuales no dependen de valores pasados.

Para que el modelo de regresión lineal sea válido, las hipótesis que se plantean deben cumplirse simultáneamente.

Las hipótesis generan inferencias estadísticas que permiten evaluar el modelo implementado.

Las condiciones de normalidad de las variables de regresión y la variable dependiente, sus relaciones lineales y la inexistencia de multicolinealidad entre las variables independientes pueden ser ajustadas mediante transformaciones no lineales como se analizará posteriormente.

2.2.3 Bondad de ajuste de datos al modelo de regresión lineal

La bondad de ajuste del modelo permite, mediante indicadores estadísticos, demostrar las hipótesis planteadas en la sección 2.2.2. Además permiten determinar cuanta variabilidad de la variable dependiente es explicada por las variables independientes.

A continuación se presenta, para cada indicador, su formulación y análisis correspondiente.

2.2.3.1 Coeficiente de correlación lineal simple (r)

Este coeficiente mide el grado de asociación lineal entre dos variables. Está dada por la siguiente ecuación:

$$r = \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_i (X_i - \bar{X})^2 * \sum_i (Y_i - \bar{Y})^2}} \quad (2-3)$$

donde X y Y son las variables que se analizan con sus respectivas medias \bar{X} y \bar{Y} y r es el coeficiente de correlación lineal.

El valor de r oscila entre 1 (fuerte asociación lineal positiva: a medida que aumenten los valores de una variable aumentarán los de la otra) y -1 (fuerte asociación lineal negativa: a medida que aumenten los valores de una variable disminuyen los de la otra). Si el valor de este estadístico se aproxima a 0, significa que entre las dos variables no existe asociación lineal y, en consecuencia, no es posible determinar un modelo de regresión lineal.

Una forma de verificar la relación lineal entre dos variables es realizar un gráfico de dispersión. Esta gráfica permite intuitivamente observar la relación entre las variables: si la nube de puntos adquiere una forma indefinida y muy dispersa, significa que no existe de relación entre las dos variables. Si por el contrario, se observa una forma definida y proximidad entre los puntos, habrá relación entre las variables caracterizada por la forma y distribución que la nube de puntos adopte [26].

Para determinar si la asociación es estadísticamente significativa, podemos contrastar la hipótesis nula, H_0 , de que el coeficiente de correlación lineal r es igual a 0. Si el *valor-p* asociado al estadístico de contraste es menor que el nivel de significación elegido (normalmente 0.05) rechazaremos H_0 .



Conviene considerar que el coeficiente de correlación está relacionado con el tamaño de la muestra; cuanto mayor es el tamaño de la muestra, mayor es el coeficiente de correlación.

2.2.3.2 Coeficiente de correlación múltiple al cuadrado o coeficiente de determinación (r^2)

47

Este coeficiente es consecuencia de la igualdad conocida como el teorema fundamental de la descomposición de las varianzas:

$$\sum_i (Y_i - \bar{Y})^2 = \sum_i (\hat{Y}_i - \bar{Y})^2 + \sum_i (Y_i - \hat{Y}_i)^2 \quad (2-4)$$

donde Y_i es la variable que se modela, \bar{Y} es su valor medio y \hat{Y}_i es el resultado del modelo.

La ecuación (2-4) indica que la suma de los cuadrados de las muestras de la variable Y respecto a su media, se puede descomponer en términos de la varianza residual. Consecuencia de la igualdad de descomposición de la varianzas, es posible plantear el índice de la bondad de ajuste r^2 , como razón de la varianza explicada por el modelo de regresión respecto a la varianza total.

El estadístico r^2 mide la proporción de variabilidad de la variable dependiente, explicada por la variable independiente introducida o por la recta de regresión determinada. Su valor multiplicado por 100 es el porcentaje de variabilidad explicada. Su cálculo es según la siguiente ecuación:

$$r^2 = \frac{\sum_i (\hat{Y}_i - \bar{Y})^2}{\sum_i (Y_i - \bar{Y})^2} = 1 - \frac{\sum_i \hat{u}_i^2}{\sum_i (\hat{Y}_i - \bar{Y})^2} \quad (2-5)$$

donde Y_i es la variable modelada con media \bar{Y} , \hat{Y}_i es la predicción y \hat{u}_i es la media de \hat{Y}_i .

De la ecuación para r^2 se verifica que su valor oscila entre 0 y 1. Un valor cercano a uno revela que las variables de regresión en conjunto explican en gran medida la variabilidad de Y . Un valor muy pequeño del coeficiente indica que el modelo no explica satisfactoriamente la variable dependiente.

Este coeficiente presenta varios inconvenientes al momento de valorar si el modelo es adecuado. El valor de r^2 aumenta al ingresar una nueva variable explicativa al modelo, sin importar la aportación de la nueva variable agregada. Además no toma en cuenta que debe estimarse un nuevo parámetro con la misma cantidad de muestras. Puede tenerse un coeficiente cercano a 1, sin embargo pueden existir violaciones de alguna hipótesis básica. Por ello no puede confiarse únicamente de este coeficiente para determinar la bondad de ajuste del modelo.

Este problema es evitado por el coeficiente de determinación ajustado.

2.2.3.3 Coeficiente de determinación ajustado (*Adjusted r^2*)

Este coeficiente no aumenta, necesariamente, a medida que añadimos variables a la ecuación. Su valor queda ajustado por el número de observaciones y el número de variables independientes incluidas en la ecuación. Tiene en cuenta los grados de libertad tanto de la suma de cuadrados residual ($N-K$), como de la suma de cuadrados total ($N-1$). Está dado por la ecuación:

$$\overline{r^2} = 1 - \frac{\sum \frac{\hat{u}_i^2}{N-K}}{\frac{\sum (Y_i - \bar{Y})^2}{N-1}} = 1 - \frac{N-1}{N-K} (1 - r^2) \quad (2-6)$$

siendo $\overline{r^2}$ es el coeficiente de determinación ajustado, N es el número de muestras de cada variable de regresión y de la variable dependiente, K es el número de variables de regresión y r^2 es el coeficiente de determinación.



El valor del coeficiente de determinación ajustado, como puede inferirse de la ecuación (2-6), varía desde $-\infty$ a R^2 . El coeficiente disminuye si al ingresar una nueva variable explicativa no compensa la pérdida de grados de libertad al tener que estimar nuevos parámetros.

Si el coeficiente de determinación ajustado toma valores negativos, significa que el modelo no describe adecuadamente el proceso que ha generado datos.

2.2.3.4 Prueba de significancia individual

Los coeficientes de regresión β de la ecuación (2-1) ponderan a las variables de regresión X para generar el modelo aproximado de $\mu_{Y|X}$. De acuerdo a esto, un análisis importante a considerar para un modelo de regresión es de contrastar si son o no relevantes los términos de regresión considerados explicativos de la variable dependiente, dada la especificación del modelo.

Estadísticamente se puede comprobar la siguiente hipótesis nula:

$$H_0: \beta_i = 0$$

$$H_a: \beta_i \neq 0$$

Donde la hipótesis nula, H_0 , implica que dada la especificación del modelo, una vez se ha controlado por el resto de factores incluidos como variables explicativas, el efecto marginal de la variable X_i sobre el valor medio de la variable dependiente es cero. Dado que en la hipótesis alternativa H_a se contempla la posibilidad de que el coeficiente, de ser distinto de cero, pueda ser indistintamente negativo o positivo, el contraste es a dos colas. Normalmente en estos contrastes, conocidos con el nombre de contrastes de significatividad individual, se considera esta alternativa. El estadístico de contraste y su distribución bajo la hipótesis nula es:

(2-7)

$$t_j \stackrel{H_0}{\sim} t(N-k)$$

donde la distribución t es dependiente de los grados de libertad $\nu = N - K$, siendo N el número de muestras y k el número de variables regresoras.

La hipótesis nula tiene un nivel de significancia α según la probabilidad seleccionada. Por lo general su valor es 0.05, 0.01 o 0.001, siendo el más común 0.05.

La distribución t es inversamente proporcional al número de muestras y al número de variables regresoras. Esto significa que al eliminar una de las variables después de comprobar la validez de H_0 , las variables restantes influyen en mayor nivel a la variable dependiente.

Modelos donde uno o más de los parámetros de regresión son insignificantes tienden a ser inestables, es decir si se quitan o se añaden muestras, los valores de los parámetros cambian drásticamente, por ejemplo de positivo a negativo [27].

Una alternativa de para determinar el contraste es utilizar el *valor-p*. Este valor representa una probabilidad que indica cuál sería el menor nivel de significación que se tendría que elegir para rechazar la hipótesis nula, dada la realización muestral estadística [28].

Si el contraste es a una cola bajo la hipótesis nula H_0 , el *valor-p* está dado por:

$$\text{valor} - p = \Pr(t_j > t_j^m | H_0) \quad (2-8)$$

donde la función de probabilidad Pr está determinado por la distribución t bajo la hipótesis nula H_0 , para un nivel de significancia α seleccionado.

Si el *valor-p* es inferior al nivel de significación, entonces la hipótesis nula es rechazada. Cuanto menor sea el *valor-p*, más significativo será el resultado.

2.2.3.5 Análisis de varianza y la estadística F

La técnica de análisis de varianza (ANOVA por sus siglas en inglés) permite comparar los valores medios que toma la variable dependiente en n observaciones en donde cada una de éstas es diferente de otra. En el contexto de los modelos de predicción, este análisis se utiliza para aclarar la calidad de la ecuación de regresión encontrada.

La prueba hipótesis nula para determinar si una cantidad significativa de la variación de Y se explica con el modelo, consiste en comprobar que:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0 \quad (2-9)$$

siendo β los coeficientes de regresión.

Según [24], la prueba de hipótesis nula estará en función de las expresiones mostradas en la Tabla 2-1.

Tabla 2-1. Tabla ANOVA del modelo de regresión

Fuente	Suma de cuadrados	Grados de libertad	Cuadrados medios	F
Regresión	$SS_R = \sum_i (\hat{Y}_i - \bar{Y})^2$	k	$MS_R = \frac{SS_R}{k}$	$f = \frac{MS_R}{MS_E}$
Error	$SS_E = \sum_i (Y_i - \hat{Y}_i)^2$	n-k-1	$MS_E = \frac{SS_E}{n - (k + 1)}$	
Total	$SS_T = \sum_i (Y_i - \bar{Y})^2$	n-1		

La tabla de análisis de varianza (o tabla ANOVA) se basa en que la variabilidad total de la muestra puede descomponerse entre la variabilidad explicada por la regresión y la variabilidad residual. La tabla de ANOVA proporciona el estadístico F a partir del cual podemos contrastar la hipótesis nula, H_0 , de que r^2 es igual a 0, es decir que la ecuación de regresión es una constante.

El estadístico F y su *valor-p* [28], determinan si por lo menos alguna de las variables de regresión es importante en el modelo. Si el *valor-p* es menor que el nivel de significación (normalmente 0.05), rechazaremos la hipótesis nula planteada.

2.2.3.6 Análisis de residuos

La hipótesis de normalidad del error y la condición de que el error no es autocorrelacionado se analiza en esta sección.

La suposición de normalidad de los residuos se puede contrastar gráficamente. Esto puede realizarse de dos maneras: (1) el gráfico de probabilidad normal, que nos da idea de cómo se distribuyen los residuos en relación a la distribución normal. Si la distribución de los residuos es normal, los puntos se sitúan sobre la diagonal del gráfico. Por lo contrario, en la medida que aparecen dispersos y formando líneas horizontales respecto a la diagonal, habrá más residuos y el ajuste será peor; (2) el gráfico de residuos tipificados compara gráficamente, al superponer la curva de distribución normal, la función de distribuciones acumulada observadas en la muestra con la función de distribución acumulada esperada bajo supuestos de normalidad. En la Figura 2-1 se muestra un ejemplo de estas gráficas.




Figura 2-1. Gráficas de normalidad del residuo

Una herramienta adicional de prueba de normalidad del error es la gráfica de residuales en función de las predicciones. En la Figura 2-2 se muestran diferentes comportamientos del error.

Se desea el comportamiento de la gráfica de la izquierda (Figura 2-2); los puntos pueden ser encerrados en una banda horizontal lo que indica una varianza constante.




Figura 2-2. Gráfica de residuales en función de las predicciones

La gráfica del centro (Figura 2-2) indica que la varianza no es constante, limitación que puede ser superada mediante una transformación no lineal. La gráfica de la derecha indica no linealidad, entonces será necesario considerar otras variables de regresión en el modelo [29].

Adicionalmente, puede realizarse la prueba de normalidad de residuo mediante el test de Anderson-Darling. Este test es de hipótesis nula, definido de la siguiente forma:

$$\begin{aligned} H_0: & \text{Los datos siguen una distribución normal} \\ H_a: & \text{Los datos no siguen una distribución normal} \end{aligned}$$

La hipótesis nula H_0 se rechaza, con un intervalo de confianza α (generalmente de valor 0.05), si el estadístico *valor-p* asociado al test es menor que α , y por tanto se concluye que los datos evaluados no siguen una distribución normal.

Para probar la hipótesis de que el error no es auto-correlacionado se usa el estadístico de Durbin-Watson que permite medir el grado de auto-correlación entre el residuo correspondiente a cada observación y el anterior. Si el valor del estadístico es próximo a 2, los residuos están no están correlacionados; si se aproxima a 4, estarán negativamente correlacionados; y si se aproximan a 0 estarán positivamente correlacionados.

2.2.4 Transformación Box-Cox de la variable dependiente

Si la hipótesis de la normalidad del error no puede ser satisfecha por las observaciones originales de la variable dependiente, una transformación no lineal puede mejorar los resultados.

En la metodología presentada en [27], para ajustar un modelo planteado en caso de una respuesta insatisfactoria, se propone utilizar la transformación Box-Cox.

La transformación Box-Cox permite obtener de forma concurrente, una varianza del error constante y distribuida normalmente [25]. La transformación puede realizarse tanto a las variables independientes como a la variable dependiente. En el presente trabajo, y siguiendo la propuesta de [27], se trabajará únicamente con la transformación a la variable dependiente.

Si la variable y dependiente únicamente tiene valores positivos, su transformación se puede realizar de la siguiente manera:

$$y_i(\lambda) = \begin{cases} \frac{y_i^\lambda - 1}{\lambda} & \lambda \neq 0 \\ \log(y_i) & \lambda = 0 \end{cases} \quad (2-10)$$

Donde $y_i(\lambda)$ es la variable transformada y λ es el parámetro de conversión.

La transformación Box-Cox permite efectivamente obtener un modelo lineal de un sistema cuyo comportamiento no es lineal.

Para los datos del ejemplo 1 presentado en [27] se muestra la aproximación, mediante regresión lineal, obtenida con la transformación Box-Cox en la Figura 2-3.




Figura 2-3. Ajuste con transformación Box-Cox y gráfica de residuos

La mejor aproximación se obtiene cuando se considera la transformación no lineal Box-Cox. La gráfica de residuos muestra que la varianza del error es más pequeña y constante cuando se realiza la transformación.

2.2.5 Intervalo de confianza e intervalo de predicción

55

El intervalo de confianza proporciona un rango de valores dentro del cual se puede asegurar que, con una probabilidad de $(1-\alpha)*100\%$, se encuentra la media poblacional de la variable dependiente Y para un valor de la variable de regresión X dado. Las ecuaciones en modo matricial para este análisis se han tomado de [24].

Un intervalo de confianza de $(1-\alpha)*100\%$ para la respuesta media $\mu_{Y|x}$ es:

$$\hat{y}_0 - t_{\alpha/2} s \sqrt{x_0'(X'X)^{-1}x_0} < \mu_{Y|x} < \hat{y}_0 + t_{\alpha/2} s \sqrt{x_0'(X'X)^{-1}x_0} \quad (2-11)$$

donde \hat{y}_0 es la predicción obtenida con el modelo de regresión lineal múltiple (MLR), $t_{\alpha/2}$ es un valor de distribución t con $n - k - 1$ grados de libertad, s^2 se define de la siguiente forma:

$$s^2 = \frac{SSE}{n - k - 1}$$

dado:

$$SSE = \sum_{i=1}^n ((y_i - \hat{y}_i)^2) = \sum_{i=1}^n (e_i^2)$$

x_0 es una condición específica de las variables X para el cual se obtiene el valor de regresión \hat{y}_0 ; y se define la matriz de las variables de regresión:

$$X = [1, X_1, X_2, \dots, X_k]$$

de modo que: $x_0 = [1, x_{10}, x_{20}, \dots, x_{k0}]$

n es el número de muestras , y s^2 es el estimador de la varianza del error del modelo.

Por otra parte, el intervalo de predicción es un rango dentro del cual se puede estar seguro en un $(1-\alpha)*100\%$ que la variable dependiente y se encuentra entre esos valores para un x (variable de regresión) dado.

Un intervalo de predicción de $(1-\alpha)*100\%$ para una respuesta de y_0 está dado por:

$$\hat{y}_0 - t_{\alpha/2} s \sqrt{1 + x_0'(X'X)^{-1}x_0} < y_0 < \hat{y}_0 + t_{\alpha/2} s \sqrt{1 + x_0'(X'X)^{-1}x_0} \quad (2-12)$$

donde las variables se definen de igual forma que para la ecuación (2-11).

Los intervalos de confianza y predicción son dependientes del número de muestras n , de manera que al incrementarse este número se reducen los intervalos. En el caso del intervalo de confianza, el rango puede reducirse cuanto se desee en función de incrementar n . Sin embargo para el caso del intervalo de predicción, su valor no puede ser reducido a menos de $2 * t_{\alpha/2} s$. Esto es debido a que este último refleja, además de que la recta de predicción representa exactamente la media verdadera de la variable dependiente para un valor de x , la variabilidad individual de y alrededor de la variable verdadera.

El valor del parámetro α por lo general es de 0.05, siendo también comunes los valores de 0.01 y 0.1. A lo largo de este trabajo se considerará α de 0.05.

Para el ejemplo 1 considerado en [27] se muestra los resultados de los intervalos determinados en la Figura 2-4.




Figura 2-4. Intervalos de confianza y predicción

Siempre el intervalo de predicción será mayor que el intervalo de confianza.

2.2.6 Selección de las variables de regresión

En esta sección se analiza el proceso de selección de las variables de regresión.

Incluir una variable independiente, en un modelo de regresión, no necesariamente significa que esta variable tenga un efecto importante en el ajuste del modelo; de hecho es probable que este ajuste disminuya.

La hipótesis de alta correlación lineal entre cada variable de regresión y la variable dependiente, y la hipótesis de la inexistencia de multicolinealidad entre las variables de regresión, presentadas en la sección 2.2.2, generan estadísticos que evitan la inclusión de variables no adecuadas para la técnica de regresión lineal múltiple. La matriz de correlación permite verificar estas hipótesis.

La metodología de selección de variables *stepwise* utiliza la matriz de correlación para eliminar y seleccionar variables en el proceso de modelación lineal. Esta metodología será utilizada en este trabajo.

2.2.6.1 Matriz de correlación

La matriz de correlación \mathbf{R} es una matriz cuadrada de $k \times k$ (siendo k el número de variables de regresión) constituida por los coeficientes de correlación, presentadas en la sección 2.2.3.1, de cada pareja de variables de regresión.

La matriz \mathbf{R} es simétrica, con unos en la diagonal y los coeficientes de correlación lineal r_{ij} en las posiciones no diagonales. Su ecuación es:

$$\mathbf{R} = \begin{bmatrix} 1 & r_{12} & \dots & r_{1k} \\ r_{21} & 1 & \dots & r_{2k} \\ \dots & \dots & \dots & \dots \\ r_{k1} & r_{k2} & \dots & 1 \end{bmatrix} \quad (2-13)$$

donde el coeficiente de correlación r_{ij} cuantifica la relación lineal entre las variables de regresión X_i y X_j .

El análisis de la matriz de correlación permite evitar la multicolinealidad entre las variables de regresión. La multicolinealidad produce que el modelo de regresión por mínimos cuadrados resulte inadecuado.

Una inspección de la matriz de correlación permitirá observar la existencia de altos coeficientes de correlación entre los pares de variables de regresión. Sin embargo cuando la cantidad de variables es alta no es siempre seguro encontrar un alto valor para los coeficientes de correlación de los pares de variables con alto coeficiente de correlación.

Por tanto debe definirse un indicador que identifique la existencia de multicolinealidad entre las variables analizadas.

En [29] se define el parámetro de condición κ de \mathbf{R} , cuya expresión es de acuerdo a la expresión siguiente:

$$\kappa = \frac{\lambda_{max}}{\lambda_{min}} \quad (2-14)$$



En donde λ_{\max} y λ_{\min} son los valores máximo y mínimo del vector de eigenvalores de \mathbf{R} .

El criterio es que si $\kappa < 100$ significa que no hay problema grave de multicolinealidad. Si los valores están entre 100 y 1000 puede decirse que existe una multicolinealidad de moderada a fuerte. Sin embargo si el valor de κ es mayor a 1000 significa que existen variables fuertemente correlacionadas de forma lineal.

Adicionalmente se requiere un indicador individual de las correlaciones que permita seleccionar las variables adecuadas. La prueba de hipótesis nula de falta de correlación entre cada par de variables de regresión genera un estadístico F y su *valor-p*. Cada *valor-p* es la probabilidad de obtener una correlación tan grande como el valor observado por azar, cuando la verdadera correlación es cero. Si el *valor-p* es pequeño (menor a 0.05, por ejemplo) entonces la correlación es significativa.

2.2.6.2 Selección de las variables del modelo mediante el método *stepwise* o regresión paso a paso

El método más utilizado para la selección de las variables de regresión, es el *stepwise* [26] y será el que se emplee para la selección del modelo en el presente trabajo.

En el análisis de regresión lineal múltiple la construcción de su correspondiente ecuación se realiza introduciendo las variables una a una; “paso a paso”. La finalidad perseguida es buscar, de entre todas las variables de regresión disponibles, el menor conjunto de variables explicativas posibles; aquellas que realmente son significativas para el modelo.

El procedimiento implica que: (1) iniciando sin ninguna variable en el modelo, en cada paso solo se introduce aquella variable que cumple ciertos criterios de probabilidad de entrada; (2) una vez introducida la variable, en cada paso se valora si alguna de las variables cumplen los criterios de probabilidad de salida; y (3), en cada paso se valora la bondad de ajuste de los datos al modelo de regresión lineal y se calculan los parámetros del modelo verificado en dicho paso.

Para evitar un bucle infinito en el proceso se establece un número límite de pasos. Normalmente este límite es el que equivale al doble del número de variables independientes.

A continuación se definen los criterios de probabilidades de entrada y salida utilizadas en el proceso de selección del modelo paso a paso o *stepwise*.

Criterio de probabilidad de entrada: Se determina el *valor-p* asociado al estadístico t según la ecuación (2-7), que indica si la información proporcionada por cada una de las variables es redundante. Este *valor-p* debe ser menor a un valor crítico que por lo general es de 0.05, en cuyo caso la variable se introduce al modelo.

Criterio de probabilidad de salida: Se utiliza también el *valor-p* asociado al estadístico t . El método comprueba que las variables introducidas sigan siendo significativas. Se elimina la variable con el menor valor del estadístico t siempre que esto no implique un descenso demasiado alto en el coeficiente de determinación r^2 .

El proceso se inicia sin ninguna variable independiente en la ecuación de regresión y el proceso concluye cuando no queda ninguna variable fuera de la ecuación que satisfaga el criterio de selección y el criterio de eliminación, es decir que garantiza que las variables seleccionadas son significativas y que ninguna variable seleccionada sea redundante.



2.2.7 Capacidad predictiva del modelo

El uso más común de los modelos de regresión múltiple es la predicción. Es indispensable, por tanto, determinar un indicador de la capacidad predictiva del modelo.

La suma de cuadrados de error de predicción conocida como la estadística PRESS es ampliamente utilizada para la comparación entre modelos de regresión [29],[30].

2.2.7.1 Estadístico PRESS

Este estadístico mide lo bien que funciona un modelo de regresión para predecir nuevos datos; es decir es un indicador de la capacidad de predicción del modelo.

El estadístico PRESS se define de la siguiente forma [24]:

$$PRESS = \delta_i^2 = \left(\frac{e_i}{1 - h_{ii}} \right)^2 \quad i = 1, 2, \dots, n \quad (2-15)$$

Donde los términos δ_i son conocidos como residuos PRESS, $e_i = Y_i - \hat{Y}_i$ es el error de predicción, h_{ii} representa la varianza del valor ajustado de \hat{Y}_i cuyos valores pertenecen a la diagonal de la matriz de HAT:

$$H = X * (X'X)^{-1}X'$$

Siendo $X = [1 \ x_1 \ x_2 \ \dots \ x_n]$ la matriz de las variables de regresión.

El modelo que se selecciona es aquel con menor valor de PRESS.

Un estadístico adicional de predicción R_{pred}^2 se define a partir del estadístico PRESS de la siguiente forma:

$$R_{pred}^2 = 1 - \frac{PRESS}{\sum_i (Y_i - \bar{Y})^2} \quad (2-16)$$

Cuya interpretación es similar a la de r^2 , es decir se elige el modelo con el valor más alto de este estadístico.

2.3 Modelación Dinámica

En esta sección se presenta el método de modelación autorregresivo. En este método los diferentes periodos de retraso en la variable dependiente se toman como variables independientes o explicativas en un modelo de regresión. Luego el modelo se ajusta a los datos mediante la técnica de los mínimos cuadrados de forma idéntica como se desarrolla en los modelos de regresión lineal.

Para determinar el número de desfases, correlacionados significativamente, que se incluirán en el modelo se analiza la función de autocorrelación.

2.3.1 Modelo autorregresivo

El modelo autorregresivo se escribe según la ecuación:

$$Y_k = \beta_0 + \beta_1 X_{1k} + \beta_2 X_{2k} + \dots + \beta_{ik} X_{ik} + \gamma_1 Y_{k-1} + \gamma_2 Y_{k-2} + \dots + \gamma_j Y_{k-j} + U_k \quad (2-17)$$

donde Y_k es la variable dependiente modelada, X son las variables independientes llamadas variables de regresión, β y γ son los coeficientes de regresión, y U es el error de predicción. El subíndice k indica el número de la muestra actual; de este modo el término Y_{k-j} se refiere a la muestra retrasada j veces de la variable dependiente.

El error U tiene las mismas propiedades que en caso del modelo de regresión lineal.

El modelo de aproximación a determinarse es:

$$Y_k = b_0 + b_1 X_{1k} + b_2 X_{2k} + b_3 X_{3k} + \dots + b_{ik} X_{ik} + g_1 Y_{k-1} + g_2 Y_{k-1} + \dots + g_j Y_{k-j} + e \quad (2-18)$$



donde Y es la variable dependiente, X son las variables de regresión independientes, e representa el error residual del modelo, b y g son los parámetros estimados de los coeficientes de regresión lineal β y γ obtenidos mediante la técnica de los mínimos cuadrados.

El modelo representado por la ecuación (2-18) es un modelo de regresión lineal múltiple, donde se han incluido como variables explicativas los retrasos de la variable dependiente.

En la modelación autorregresiva, los valores de los retrasos de la variable dependiente deben tener alta correlación con su valor actual, esto de acuerdo a una de las hipótesis planteadas en el modelo de regresión lineal. Entonces, en la modelación autorregresiva, se puede plantear como variables explicativas de 1 a j retrasos de la variable dependiente; y luego mediante la técnica *stepwise*, a través de las pruebas de significatividad individual, se seleccionará los valores con retrasos adecuados y que mejor explican la dinámica de la variable modelada.

La bondad de ajuste del modelo autorregresivo son las mismas que se presentaron para el modelo de regresión lineal múltiple.

2.3.2 Autocorrelación

La autocorrelación se refiere a la correlación entre los miembros de una serie de números dispuestos en el tiempo. Puede ser explotado para las predicciones; una serie autocorrelacionada en el tiempo es predecible, probabilísticamente, porque los valores futuros dependen de los valores actuales y pasados. Existen tres herramientas para evaluar la autocorrelación de una serie temporal: (1) la trama de series de tiempo, (2) el diagrama de dispersión lento, y (3) la función de autocorrelación.

Para el presente trabajo se utilizará la función de autocorrelación.

2.3.2.1 Funciones de autocorrelación y autocorrelación parcial

Las funciones de autocorrelación y de autocorrelación parcial miden la relación estadística entre las observaciones de una serie temporal.

La función de autocorrelación parcial mide el aporte que, a las variaciones de Y_k , tiene el desfase Y_{k+j} si se aísla todos los efectos posibles de los restantes retrasos. Es una importante herramienta en el análisis de datos dirigido a la identificación de la medida de desfase en un modelo autorregresivo.

La función de autocorrelación se define como la correlación cruzada de la señal consigo misma. Es decir, para una señal discreta Y , la autocorrelación es simplemente la correlación entre los valores de Y_k y Y_{k+j} , donde j representa un desplazamiento de la serie temporal Y . La función de autocorrelación considera el hecho que la correlación entre Y_k y Y_{k+j} se debe a dependencia creada por los retardos intermedios existentes entre ellos.

Para determinar el número de retrasos que se incluirán en la modelación autorregresiva, es necesario analizar las funciones de autocorrelación muestral [31][32][33].

Una importante guía sobre la persistencia en una serie temporal, está dado por una serie de valores denominados coeficientes de autocorrelación muestral, que miden la correlación entre observaciones a diferentes tiempos. El conjunto de estos coeficientes de autocorrelación, interpretados como función de separación en el tiempo es la función de autocorrelación muestral (acf), que se definen de acuerdo a la siguiente ecuación:

$$r_k = \frac{\sum_{i=1}^{N-k} (x_i - \bar{x})(x_{i+1} - \bar{x})}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (2-19)$$

donde, r_k es el coeficiente de correlación en el retraso k , y \bar{x} representa la media de la serie temporal x .

El gráfico de la función de autocorrelación en función del desfase k (gráfico de r_k) es denominado correlograma (Figura 2-5).

El análisis de r_k permite determinar si la serie x_k es aleatoria o si sus diferentes desfases están correlacionados. Si la serie es aleatoria, sus desfases no están correlacionados y $r_k \cong 0$; esto significa x_1, x_2, \dots, x_N son independientes y puede demostrarse que:

$$E(r_k) = -\frac{1}{N}$$

y,

$$Var(r_k) = 1/N$$

Siendo N el número de elementos de la serie x .

El límite del intervalo de confianza del 95% para el correlograma, por tanto puede, ser graficado como $-\frac{1}{N} \pm 2/\sqrt{N}$, y aproximado por $0 \pm 2/\sqrt{N}$. Valores de magnitud de retrasos r_k fuera del intervalo de confianza son autocorrelacionados.

Un valor de magnitud de r_k grande y con k cercano a 1 indica persistencia del valor de la serie temporal. En la Figura 2-5 se muestra un ejemplo de la gráfica de un correlograma para una serie temporal de 100 muestras. El intervalo de confianza es 0 ± 0.2




Figura 2-5. Gráfica de la autocorrelación muestral en función del desfase

En la Figura 2-5 se observa que no existe correlación entre los desfases de la señal (ningún valor de r_k fuera del intervalo de confianza), así que su comportamiento es aleatorio.

2.4 Modelación Neuronal

Las redes de neuronas artificiales (ANN) procesan información mediante la interconexión de unidades básicas llamadas neuronas. La neurona recibe señales de sensores externos o de otras neuronas a través de sus conexiones de entrada.

Estas conexiones tienen asociado dos parámetros: el primero se trata de un peso W que se encarga de asignar un factor de ponderación para dar una mayor o menor importancia a la señal que transmite.

Las señales de entrada mencionadas se procesan en la neurona de forma que son tratadas cada una con su peso de conexión y posteriormente se suman. El segundo parámetro es conocido como umbral b , el cual no depende de ninguna entrada y se trata de un parámetro interno de la red.

El diseño de la red neuronal se muestra en la Figura 2-6. Primero se realiza una suma ponderada conjuntamente con los umbrales, luego se aplica una función de transferencia que puede ser lineal o no lineal. Si la función es lineal se reduce a una regresión lineal de datos. Si la función es no lineal permite la capacidad de generalización en diversos aspectos como por ejemplo redes neuronales utilizadas para ajustar funciones, otras para clasificar conjuntos de datos y otros para reconocer patrones. Para este caso la red neuronal permite la predicción de valores de variables de calidad en la fabricación de cemento.




Figura 2-6. Diseño de la red neuronal

2.4.1 Modelos de redes neuronales

El primer modelo se trata de un perceptrón multicapa *feedforward*, es decir, una red neuronal con varias capas de neuronas interconectadas sin ningún tipo de conexiones de realimentación como se muestra en la Figura 2-7. El perceptrón multicapa es una estructura unidireccional donde la información va desde las neuronas de entrada a las de salida sin ningún tipo de lazo de control o realimentación [34]. Puede aproximar cualquier función continua que contenga al menos una capa oculta de neuronas. La aplicación de la red neuronal es fácil y posee una gran aplicabilidad.




Figura 2-7. Estructura del perceptrón multicapa

El perceptrón multicapa es una red neuronal adecuada para filtrar ruido, aproximar relaciones no lineales, etc. Por lo que es muy útil para resolver problemas reales como la predicción de los valores de las variables de calidad, como se presenta en [35]. El perceptrón multicapa posee una serie de limitaciones, como el largo proceso de aprendizaje para problemas con muchas variables, su alta conectividad, entre otros.

El segundo modelo es una red NARX (nonlinear autoregressive exogenous model), que es similar a la anterior pero presenta una realimentación desde su salida hasta las neuronas de entrada como se observa en la Figura 2-8.




Figura 2-8. Estructura de la red NARX

El último modelo es una red recurrente como la NARX pero que además de realimentar la salida de la red, realimenta el error cometido por la misma en predicciones pasadas.

El método escogido dependerá de las condiciones del problema para el uso una red u otra. A continuación se realiza una descripción de los modelos mencionados.

2.4.2 Estructura de la red

Las redes neuronales están compuestas por la interconexión de neuronas. Estas conexiones pueden ir de una entrada a una neurona, de una neurona a una salida, o de una neurona a otra neurona. Además la red puede presentar realimentaciones de la información a través de la red como una entrada más. La estructura típica es la llamada *feedforward*, y consta básicamente de tres tipos de capas de neuronas como se observa en la Figura 2-7.

- Capa de entrada: es donde se incorporan los valores de las entradas y se introducen en la red para pasar la información a las siguientes capas. Esta capa proporciona la información de las variables de entrada.
- Capa de salida: se recoge la información proveniente de las neuronas de la capa de entrada y se envía a las salidas correspondientes de la red. Esta capa tiene el mismo número de neuronas correspondientes al número de salidas.



- Capas ocultas: es la capa o múltiples capas que hay entre la capa de entrada y la capa de salida. Son las encargadas de establecer las relaciones entre las variables de entrada. Dependerá de las funciones de activación. La cantidad de capas ocultas aumenta el tiempo de procesamiento.

2.4.3 Tipos de redes neuronales

Según [36] existen cuatro modelos básicos de redes neuronales a partir de los cuales se desarrollan modelos más específicos:

- Redes de propagación hacia delante: perceptrón simple, multicapa, redes ADALINE, mapas de Kohonen.
- Redes recurrentes: red Elman, red Hopfield, NARX.
- Redes estocásticas: máquina de Boltzmann y la máquina de Cauchy.
- Redes modulares: comité de máquinas o la asociación de redes neuronales

2.4.4 Modelo matemático

El funcionamiento de una red neuronal con una capa oculta se presenta en la Figura 2-6 y se describe matemáticamente por la ecuación (2-20):

$$\vec{S} = F(F(\vec{X} * W1 + b1) * W2 + b2) \quad (2-20)$$

Donde $W1$ y $W2$ son la matriz de pesos correspondientes a cada neurona. $b1$ y $b2$ son los umbrales correspondientes a cada neurona. \vec{S} es el conjunto de estados posibles de la red neuronal. \vec{X} corresponde a las entradas aplicadas en la red. Y sea F la función de activación lineal dada por:

$$F(x) = k\vec{X} \quad (2-21)$$

Al reemplazar la ecuación de la función en la salida de la red neuronal y despreciando los valores de los umbrales se obtiene:

$$\vec{S} = k(k(\vec{X} * W1) * W2) = \vec{X} * k^2 * W1 * W2 \quad (2-22)$$

La representación gráfica del modelo matemático de la red neuronal con una capa oculta se observa en la Figura 2-9:




Figura 2-9. Red neuronal con dos matrices de pesos

Además las matrices de pesos $W1$ y $W2$ pueden reemplazarse por una matriz equivalente Wt como se muestra en [34]. De esta manera cualquier combinación de neuronas y pesos a través de funciones lineales puede ser representada por una sola matriz de pesos equivalentes. En definitiva es irrelevante la adición de capas ocultas, e inadecuado utilizar funciones de activación lineales.

2.4.5 Entrenamiento de redes neuronales

El entrenamiento de las redes neuronales consta de dos fases principalmente: la primera es la fase de aprendizaje a través de la formulación de un esquema que presenta una serie de problemas, para resolver, basados en ejemplos. Los ejemplos están compuestos por parámetros de entrada que tienen alguna relación con la respuesta deseada. Conforme se presentan nuevos ejemplos a la red, esta va ajustando los pesos para solucionar el problema. La etapa de aprendizaje termina cuando la red cumple con alguna de las condiciones establecidas como: número de iteraciones o ciclos, un error de tolerancia, que los pesos converjan hacia un valor fijo, entre otros.



La segunda fase es la de validación que se realiza con un conjunto de ejemplos diferentes al de la fase de aprendizaje. Los pesos se mantienen fijos debido a que la red se encuentra establecida, la respuesta al nuevo conjunto de ejemplos será mejor dependiendo de cuan buena haya sido el entrenamiento de la red.

La importancia de los ejemplos radica en la constitución de la red neuronal, por eso deben cumplir con las siguientes características:

- Ser significativo: representa un número suficiente de ejemplos que permita a la red adaptar los parámetros correspondientes a sus pesos.
- Ser representativo: debe ser un conjunto diverso de ejemplos que representen todas las situaciones posibles del problema a resolver.

El proceso de entrenamiento de la red consiste en optimizar los parámetros de la red para encontrar la solución con el menor error posible. La reducción del error es un parámetro de convergencia. Si el criterio se cumple se detiene el entrenamiento con los parámetros actuales, caso contrario se continúa con el entrenamiento e introducción de los ejemplos. Existen otros criterios de convergencia, entre los más utilizados se encuentran:

- Número de ciclos o épocas de entrenamiento: el proceso se detiene cuando se ha ingresado a la red un número predeterminado de ejemplos.
- Error de tolerancia: el aprendizaje se detiene cuando el nivel de error se encuentra por debajo del mínimo establecido.
- Convergencia de los pesos: el proceso termina cuando los pesos ya no se modifican con la inclusión de nuevos ejemplos a la red.

2.4.5.1 Funciones de entrenamiento

El programa *MATLAB* presenta un toolbox para el trabajo con redes neuronales. Tiene incorporado una serie de funciones de entrenamiento que serán las que se utilicen para entrenar las redes. La función de desempeño por defecto para las redes *feedforward* es *mean square error* (mse). Se considera el promedio cuadrático del error entre la predicción de la red y los valores reales del sistema.

Las funciones más importantes se explican a continuación y son las que se utilizan para realizar la estimación del modelo para predecir el comportamiento de la planta de cemento.

Traingd (Training gradient descent): es el entrenamiento de disminución de gradiente. Los pesos y los umbrales se actualizan en dirección negativa del gradiente de la función de desempeño. Utiliza un parámetro de aprendizaje fijo durante todo el entrenamiento. Este factor determina el tiempo de convergencia y puede causar inestabilidad.

Traingdm (Trainnig gradient descent with momentum): es el entrenamiento de disminución de gradiente con impulso. Permite una convergencia más rápida que traingd. Incorpora un parámetro que incluye la velocidad de descenso. El momentum permite que la red responda, a más del gradiente, a la tendencia del error, por lo que ignora los cambios pequeños en el error.

Traingda (Training gradient descent with adaptative learning rate): es el entrenamiento de disminución de gradiente con tasa de aprendizaje. Permite actualizar el factor de aprendizaje durante el entrenamiento. En la primera iteración se calcula el rendimiento de la red inicial y el error cometido. Los pesos y umbrales se actualizan en cada iteración con la tasa de aprendizaje actual. Si el rendimiento y el error nuevo calculado exceden a los anteriores se ignoran los nuevos valores de los pesos y umbrales y se disminuye la tasa de aprendizaje.

Traingdx (Training gradient descent with momentum & adaptative learning rate): combina la tasa de aprendizaje adaptativa y el momentum mencionado en traingdm.

Trainrp (Training RProp): resuelve el problema de utilizar funciones de tipo sigmoides que devuelven un rango finito (entre -1 y 1). Para valores de entrada muy grandes o muy pequeños la pendiente de la función es pequeña por lo que la variación de los pesos y umbrales de la red son pequeños aunque se encuentre alejado de un mínimo.



Como solución, en lugar de variar los pesos y umbrales en función de la derivada de la función error, se toma una variación fija que depende del signo de la derivada. Si el signo de la derivada se mantiene durante varias iteraciones se incrementa la magnitud de los pesos y umbrales.

Traincgp (Training conjugate gradient with Polak-Ribiere restarts): es el entrenamiento con gradiente conjugado utilizando la actualización de Polak-Ribière. Se basa en el algoritmo de gradiente conjugado [37]. Consiste en realizar la búsqueda de la dirección que minimice la función de desempeño.

Traincgb (Training conjugate gradient with Beale-Powell restarts): Es el entrenamiento de gradiente conjugado utilizando la actualización de Beale-Powell. Intenta conseguir una convergencia más rápida al realizar una búsqueda en la dirección conjugada.

Trainbfg (Training BFGS Quasi-Newton): es un método cuasi-newtoniano. Alcanza la convergencia más rápida que las funciones de gradiente conjugado. Los algoritmos newtonianos se basan en la variación de los pesos y umbrales como se muestra en [37]. La convergencia rápida incluye un alto coste computacional.

Trainlm (Training Levenberg-Marquardt): es el entrenamiento que utiliza el método de Levenberg-Marquardt y se encuentra dentro de los métodos cuasi-newtonianos. Consigue llegar a errores pequeños inmediatamente. El algoritmo se presenta en [38]. La ventaja radica en que calcular el jacobiano J es más simple que calcular la matriz Hessiana H , por lo que reduce el coste computacional. Además cuenta con un parámetro que incluye el método del descenso del gradiente.

2.4.5.2 Funciones de activación o transferencia

Las neuronas dentro de una red neuronal se activan mediante el uso de una función de transferencia, lo cual caracteriza su respuesta a la salida de la neurona.

Las principales funciones de activación son lineales, sigmoideas, logarítmicas, tangenciales, etc. *MATLAB* incorpora tres funciones de activación que se describen a continuación.

Log-sigmoidal (logsig): es la función de transferencia logarítmica. La función recibe como entrada valores desde $-\infty$ a $+\infty$ y genera salidas entre 0 y 1. La Figura 2-10 muestra la función log-sigmoidal.




Figura 2-10. Función de activación log-sigmoidal

Tan-sigmoidal (tansig): es la función de transferencia tangencial. La función recibe como entrada valores desde $-\infty$ a $+\infty$ y genera salidas entre -1 y 1. La Figura 2-11 muestra la función tan-sigmoidal.




Figura 2-11. Función de activación tan-sigmoidal

Purelin: es la función de transferencia lineal. La salida de la función es igual a su entrada. La función de activación purelin se observa en la Figura 2-12.




Figura 2-12. Función de activación lineal



2.5 Modelación Neurodifusa

En esta sección se presenta la técnica de modelación neurodifusa.

2.5.1 Definición de sistemas neurodifusos

Los sistemas neurodifusos nacen de la combinación de las redes neuronales y de los sistemas difusos.

Las redes neuronales proporcionan la capacidad de razonamiento similar a la de un cerebro humano, compuesto por unidades de procesamiento simples como son las neuronas, adquieren y almacenan conocimiento a través del aprendizaje y los pesos de la red [39]. Los sistemas difusos incorporan el conocimiento humano para tomar decisiones mediante el uso de reglas “si-entonces” [40].

De otra manera un sistema neurodifuso es un sistema difuso entrenado por un algoritmo de aprendizaje que se deriva de las redes neuronales [41]. Las principales aplicaciones de los sistemas neurodifusos son: la clasificación y reconocimiento de patrones [42], los controladores automáticos, la aproximación de funciones y la predicción de datos [43].

Los criterios de redes neuronales ya han sido tratados en la sección 2.4. A continuación se presenta una breve explicación de los conceptos de los sistemas difusos y su aplicación.

2.5.1.1 Sistemas Difusos

La metodología de aplicación de los modelos difusos se muestra en la Figura 2-13 e incluye una etapa de fusificación, un mecanismo de inferencia basado en un conjunto de reglas y por último la etapa de defusificación.

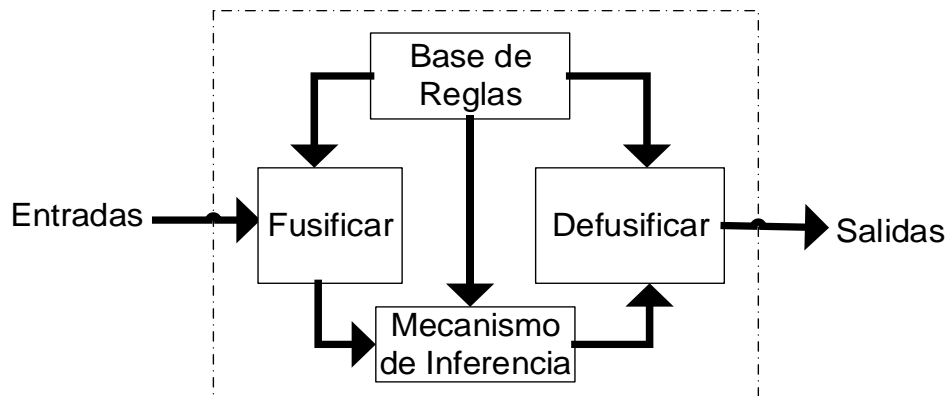


Figura 2-13. Etapas de la modelación difusa

A continuación se explica cada una de las etapas mencionadas.

2.5.1.1.1 Fusificación

Se basa en convertir las entradas reales del sistema a valores distinguibles por la lógica difusa, mediante el uso de funciones de membresía o pertenencia. Mediante el uso de estas funciones se calcula el grado de pertenencia de una variable a dicha función. Se deben distinguir los rangos de variación de las variables de entrada y los conjuntos difusos asociados con sus respectivas funciones de pertenencia [44]. El grado de verdad o pertenencia varía entre 0 y 1, siendo 0 una no pertenencia a un grupo, y 1 pertenencia total.

Las funciones de membresía más comunes y que incorpora *MATLAB* son:

trimf: es la función de membresía triangular. Es función del vector x y depende de los parámetros a , b y c . Está dada por la ecuación (2-23):

$$f(x; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (2-23)$$

La Figura 2-14 muestra la función de pertenencia triangular.




Figura 2-14. Función de membresía triangular

trapmf: es la función de pertenencia trapezoidal. Es función del vector x y depende de los parámetros a, b, c y d . La ecuación (2-24) está determinada por:

$$f(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \\ 0, & d \leq x \end{cases} \quad (2-24)$$

La Figura 2-15 presenta la función de pertenencia trapezoidal.




Figura 2-15. Función de membresía trapezoidal

gbellmf: es la función de membresía de campana generalizada. Depende de los parámetros a, b, c y su ecuación es:

$$f(x; a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \quad (2-25)$$

Donde c determina el centro de la curva. La Figura 2-16 muestra la función de pertenencia de campana generalizada.




Figura 2-16. Función de membresía de campana generalizada

gaussmf: es la función de membresía gaussiana. Es una función simétrica y depende de los parámetros σ y c . La ecuación (2-26) está determinada por:

$$f(x; \sigma, c) = e^{\frac{-(x-c)^2}{2\sigma^2}} \quad (2-26)$$

La Figura 2-17 presenta la función de pertenencia gaussiana.




Figura 2-17. Función de membresía gaussiana

gauss2mf: es la combinación de dos funciones de membresía gaussianas. Está determinada por la ecuación de la función de pertenencia gaussiana. No siempre es una función simétrica, sino que posee parámetros para determinar la forma de lado izquierdo y derecho de la función gaussiana. La Figura 2-18 muestra la función de membresía gaussiana combinada.




Figura 2-18. Función de membresía gaussiana combinada

pimf: es la función de membresía en forma de pi. Es función del vector x y los parámetros a, b, c y d que se observa en la ecuación (2-27):

$$f(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ 2 \left(\frac{x-a}{b-a} \right)^2, & a \leq x \leq \frac{a+b}{2} \\ 1 - 2 \left(\frac{x-b}{b-a} \right)^2, & \frac{a+b}{2} \leq x \leq b \\ 1, & b \leq x \leq c \\ 1 - 2 \left(\frac{x-c}{d-c} \right)^2, & c \leq x \leq \frac{c+d}{2} \\ 2 \left(\frac{x-d}{d-c} \right)^2, & \frac{c+d}{2} \leq x \leq d \\ 0, & x \geq d \end{cases} \quad (2-27)$$

La Figura 2-19 presenta la función de pertenencia en forma de pi.




Figura 2-19. Función de membresía en forma de pi

dsigmf: es la función de membresía dada por la diferencia entre dos funciones sigmoideas. Está dada por la ecuación (2-28):

$$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}} \quad (2-28)$$

La Figura 2-20 presenta la función de pertenencia de la diferencia entre funciones sigmoidales.




Figura 2-20. Función de membresía de diferencia entre dos funciones sigmoidales

psigmf: es el producto de dos funciones de membresía sigmoidales. Su ecuación está dada por la descrita en dsigmf. La Figura 2-21 muestra la función de pertenencia debido al producto de dos funciones sigmoidales.




Figura 2-21. Producto de dos funciones de membresía sigmoidales

2.5.1.1.2 Mecanismo de inferencia

Realiza la función de tomar decisiones acerca de una variable. Contiene las reglas del proceso referente a las funciones de pertenencia y a los conjuntos difusos. Las reglas son de la forma “si-entonces”. Por ejemplo la regla:

Si x_1 es A y x_2 es B entonces r_1

Donde x_1 y x_2 son las variables de entrada, A y B los conjuntos difusos y r_1 es el valor que toma la variable de salida. Las reglas se determinan dependiendo del problema o modelo a solucionar. Se pueden obtener las reglas a partir de los valores de entrada y salida del sistema.

81

Las reglas se pueden obtener en base a tres operaciones lógicas. Las operaciones son: $AND = \min(A, B)$, $OR = \max(A, B)$ y $NOT = 1 - A$. La Figura 2-22 presenta las operaciones descritas.




Figura 2-22. Operadores lógicos difusos

2.5.1.1.3 Defusificación

Es el proceso inverso a la fusificación. Se trata de convertir los valores de la lógica difusa determinada por la regla para la variable de salida en valores reales para la modelación del sistema. Existen algunos métodos de defusificación, entre los cuales se describen:

Método de Centroide (Mamdani): se aplica para sistemas continuos y se basa en encontrar el centro de masa de la función de salida. Está definido por la ecuación (2-29).

$$COA = \frac{\sum_{x=a}^b \mu_A(x) * x}{\sum_{x=a}^b \mu_A(x)} \quad (2-29)$$

La Figura 2-23 muestra un ejemplo del método del centroide.




Figura 2-23. Método del centroide

Método del máximo valor: se trata de escoger el máximo valor de la función generada por las operaciones lógicas difusas. La Figura 2-24 muestra el uso del método del valor máximo.




Figura 2-24. Método del valor máximo

Método ponderado: se trata de que la función de salida sea simétrica. La salida está determinada por la ecuación (2-30).

$$z = \frac{\sum_{i=1}^N w_i c_i}{\sum_{i=1}^N w_i} \quad (2-30)$$

La ecuación determina que entre más cerca del valor central se encuentre la salida será de menor valor mientras que cuando más lejano se encuentre será de valor mayor.

2.5.2 Clasificación de los sistemas neurodifusos

La división de los modelos neurodifusos se propone en [45]. Básicamente define su clasificación en la forma de combinar a las redes neuronales y los sistemas difusos. La clasificación propuesta es:



2.5.2.1 Modelos concurrentes

Las redes neuronales trabajan paralelamente, en forma cooperativa pero ninguno de los dos determina los parámetros de entrada del otro.

2.5.2.2 Modelos cooperativos

Las redes neuronales se utilizan para determinar las funciones de membresía o las reglas a partir de los datos de entrenamiento. Se distinguen dos fases: la de entrenamiento en la que las redes neuronales encuentran los parámetros para el sistema difuso. La segunda fase es la de funcionamiento en la que el sistema difuso trabaja solo. El agente de sintonización neuronal por refuerzo ASR [46], es un ejemplo de este tipo de modelos.

2.5.2.3 Modelos híbridos

Las redes neuronales y los sistemas difusos trabajan juntos en una misma arquitectura. Se trata de una red neuronal con parámetros difusos o un sistema difuso con parámetros determinados por las redes neuronales. Ejemplo de estos modelos es el sistema de inferencia adaptativo neurodifuso ANFIS [47]. El sistema propuesto en este documento será precisamente el modelo ANFIS que se encuentra incorporado en *MATLAB* mediante la herramienta *anfisedit*.

2.5.3 Modelo ANFIS.

El modelo ANFIS consta de un set de datos que representan las variables de entrada y una variable de salida. A través del set de datos produce un conjunto de reglas “si-entonces” tipo Takagi-Sugeno [48]. Por último incorpora un sistema de inferencia difuso.

La Figura 2-25 presenta la arquitectura general del modelo ANFIS dividido por capas. La capa 1 contiene las funciones de membresía, la salida de cada nodo especifica el grado de pertenencia para cada una de las entradas. La capa 2 calcula el grado de activación de la regla asociada. El operador lógico difuso utilizado es AND.

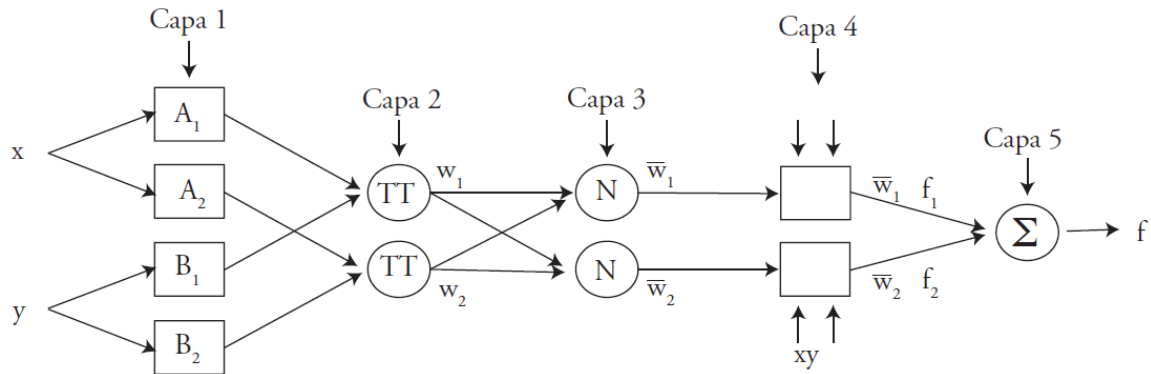


Figura 2-25. Arquitectura del modelo ANFIS [49]

La capa 3 (Figura 2-25) normaliza los grados de activación encontrados en la capa 2. La capa 4 realiza el producto del grado de activación normalizado y la salida de cada regla. Finalmente, la capa 5 muestra la salida total del sistema como la suma de todas las entradas a este nodo.

En [50] resume el proceso mediante estos 5 niveles:

1. Proceso de fusificación de las variables de entrada.
2. Se computan las reglas que salen del primer nivel
3. Normalización de las reglas
4. Se determinan los parámetros de las reglas subsecuentes; en este tipo de arquitectura se usa backpropagation para determinar los parámetros de las premisas
5. Se ajustan los parámetros usando estimación mean-square.

2.5.4 Entrenamiento de los sistemas difusos

El proceso de modelación neurodifusa consta de dos partes: la primera de una etapa de entrenamiento y la segunda la de validación. La fase de entrenamiento es desarrollada con un conjunto de datos de entrada y su salida correspondiente. Para la etapa de validación se utiliza un conjunto de datos diferente a la etapa del entrenamiento.



CAPÍTULO 3: MODELACIÓN DE LAS VARIABLES DE CALIDAD

3.1 Introducción

En este capítulo se desarrollan los modelos de las variables de calidad. Los modelos son: estadísticos, dinámicos, neuronales y neurodifusos.

Las variables disponibles para este trabajo son del circuito de molienda de cemento: secado de puzolana, premolienda y molino de cemento.

Se inicia un tratamiento de los datos disponibles. Posteriormente se procede con la selección de las variables de proceso que formarán parte de la modelación, mediante las cuatro técnicas. La selección es de acuerdo a un estudio de la matriz de correlación de las variables disponibles.

En los cuatro modelos se incluyen como variables básicas e imprescindibles, aquellas que son más influyentes en el circuito final de molino de cemento (Figura 1-2).

3.2 Identificación de variables de calidad y proceso

En esta sección se presenta el análisis de los datos de las variables de proceso y calidad del circuito de molienda de la planta industrial Guapán.

Se inicia con la identificación de las variables de proceso y calidad disponibles. Se realiza un pre-procesamiento de los datos: eliminación de variables con muy pocas muestras, alineación en el tiempo de las variables (*timestamp*) y eliminación de datos atípicos (*outliers*) de cada variable. Además se presenta un reporte estadístico de todas las variables disponibles. Finalmente en un proceso de pre-selección de las variables de modelación, algunas variables de proceso y calidad son eliminadas.

3.2.1 Base de datos

La base de datos disponible corresponde al periodo abril 2014 – abril 2015. Las variables de operación y calidad disponibles se muestran en la Tabla 3-1.

Tabla 3-1. Variables extraídas de la base de datos

Proceso	Variable	Unidades
Alimentación Premolienda	Clinker G3	tph
	Yeso G11	tph
	Caliza	tph
	Puzolana seca	thp
	Tonelada/hora	tph
Premolienda	Amperaje triturador	A
	Vibración triturador	mm/s
	Amperaje elevador	A
	Presión diferencial colector	inH2O
	Presión bomba hidráulica	mbar
	Amperaje motor vent cole	A
	Llenado silo	%
G20	Amperaje del Motor	A
	Potencia del Motor	W
	Temperatura. Cojinete norte	oC
	Temperatura cojinete sur	oC
	Temperatura piñón norte	oC
	Temperatura piñón sur	oC
	Temperatura material salida	oC
	Temperatura salida molino	oC
	Grado llenado cámara 1	%
	Grado llenado cámara 2	%
	Alimentación molino	thp
G35	Variador potencia	kW
	Consigna de velocidad	%
	Velocidad	rpm
	Retorno material	tph
Transporte	Amperaje elevador G31	A
	Amperaje elevador G47A	A
	Amperaje bomba G47	A
G39	Potencia del Motor	kW
	Consigna de Velocidad	%
	Velocidad	rmp
	Presión diferencial G38	mmH2O
G24	Presión diferencial G24	mmH2O
	Consigna de velocidad	%
Secador de puzolana	Temperatura	oC
	Alimentación puzolana	tph
	Amperaje elevador	A
	Presión diferencial colector	mbar
	Porcentaje en Silo	%
Calidad en Molino de Cemento	Temperatura	oC
	Blaine	cm2/g
	Fineza Ret Malla325	%
	Óxido de Calcio (CaO)	%
	SO3	%



Las variables G20-Potencia del motor y G39-Presión Diferencial G38 no tienen suficientes datos, de modo que se eliminan. En la Tabla 3-2 se muestran las variables que se incluirán en el análisis estadístico. Se incluye además, la notación de las variables que se utilizarán a lo largo de este trabajo.

Tabla 3-2. Variables de operación y calidad

Equipo	Variable	Notación	
Alimentación Premolienda	Clinker G3	AP	Clinker G3
	Yeso G11	AP	Yeso G11
	Caliza	AP	Caliza
	Puzolana seca	AP	Puzolana Seca
	Tonelada/hora	AP	Tonelada/hora
Premolienda	Amperaje triturador	PR	Amp. Triturador
	Vibración triturador	PR	Vibr. Triturador
	Amperaje elevador	PR	Amp. Elevador
	Presión diferencial colector	PR	Presión Dif. Colec
	Presión bomba hidráulica	PR	Presión Bomba Hidr
	Amperaje motor vent cole	PR	Amp. Mot Vent Cole
	Llenado silo	PR	Llenado Silo
G20	Amperaje del Motor	G20	Corrient del Motor
	Temperatura. Cojinete norte	G20	Temp. Cojinete Nor
	Temperatura cojinete sur	G20	Temp. Cojinete Sur
	Temperatura piñón norte	G20	Temp. Piñón Norte
	Temperatura piñón sur	G20	Temp. Piñón Sur
	Temperatura material salida	G20	T. Material Salida
	Temperatura salida molino	G20	Temp Salida Molino
	Grado llenado cámara 1	G20	Grado llenado Cam.1
	Grado llenado cámara 2	G20	Grado llenado Cam.2
	Alimentación molino	G20	Alimentación Molino
G35	Variador potencia	G35	Variador Potencia
	Consigna de velocidad	G35	Variador Seteo
	Velocidad	G35	Variador Velocidad
	Retorno material	G35	Retorno Material
Transporte	Amperaje elevador G31	TR	Elevador G31
	Amperaje elevador G47A	TR	Elevador G47A
	Amperaje bomba G47	TR	Bomba G47
G39	Potencia del Motor	G39	Potencia del Motor
	Consigna de Velocidad	G39	Seteo Velocidad
	Velocidad	G39	Velocidad
G24	Presión diferencial G24	G24	Presión Dif G24
	Consigna de velocidad	G24	Pos Comp. Vent G25
Secador de puzolana	Temperatura	SP	Temperatura
	Alimentación puzolana	SP	Alimentación Puzol
	Amperaje elevador	SP	Amp. Elevador
	Presión diferencial colector	SP	Presión Dif. Colec
	Porcentaje en Silo	SP	Porcentaje en Silo
Calidad en Molino de Cemento	Temperatura	MC	Temperatura
	Blaine	MC	Blaine
	Fineza Ret Malla325	MC	Fineza Ret Malla325
	Óxido de Calcio (CaO)	MC	Óxido de Calcio
	SO3	MC	SO3

Se dispone de 39 variables de proceso y 5 variables de calidad.

3.2.2 Pre-procesamiento de los datos: Alineación en el tiempo (*timestamp*) y eliminación de datos atípicos (*outliers*)

La base de datos proporcionada por la planta industrial Guapán, de las variables de calidad y de proceso, presentan fechas donde no se ha realizado el muestreo para algunas variables, y debido a que la modelación requiere correspondencia entre todas las variables consideradas, es necesario eliminar todas las muestras correspondientes a esas fechas. Por otra parte es necesario alinear las muestras, es decir por cada fecha disponer de todas las muestras de cada variable, generando correspondencias entre ellas.

Finalmente se requiere eliminar los datos atípicos. Esto se refiere a eliminar muestras de una variable cuyo valor no esté dentro del rango de n desviaciones estándar con respecto a la media de esa variable. Un dato atípico representa posibles errores de anotación en la base de datos por parte de los panelistas, es decir medidas que están fuera del rango de funcionamiento normal en la planta, según la información proporcionada por los mismos panelistas.

Para el proceso de *timestamp* y eliminación de *outliers* se procede como en la Figura 3-1.

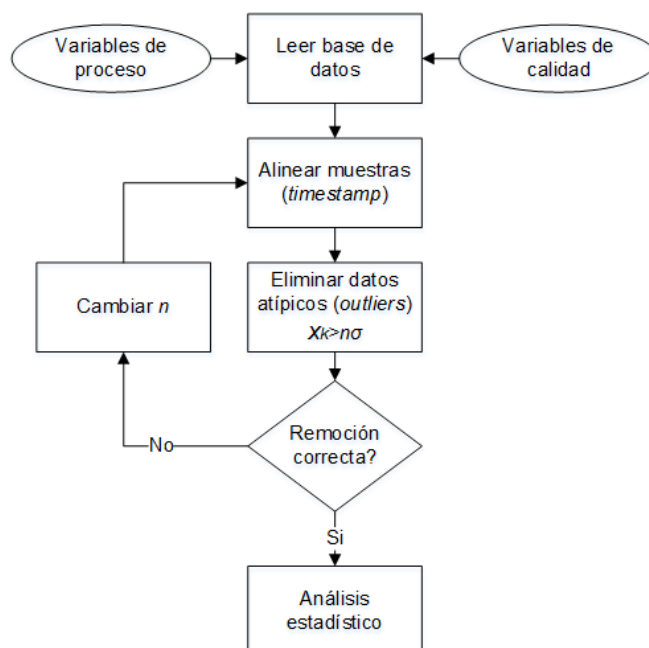


Figura 3-1. Alineación en el tiempo y eliminación de datos atípicos



En la eliminación de los datos atípicos se selecciona un valor de n común para todas las variables de proceso y calidad. Su valor se fija de acuerdo al rango de variación de: (1) las variables de proceso más significativas y que más frecuentemente se someten a ajustes durante la operación de la planta y; (2) de acuerdo al rango de variación de las variables de calidad que se pretenden modelar. Estas variables y sus rangos se muestran en la Tabla 3-3.

Tabla 3-3. Rango de valores de las variables de proceso representativas

Variable	Valor mínimo	Valor máximo
Blaine (cm ² /g)	3900	4300
Fineza (%)	3	5
G35- Consigna de velocidad (%)	69	74
G39- Consigna de Velocidad (%)	93	97
G20- Alimentación Molino (tph)	68	78

De acuerdo a los valores mostrados en la Tabla 3-3 se ajusta n igual a 1.5. Los datos atípicos a eliminarse de todas las variables de calidad y de proceso son las muestras que se encuentren fuera de 1.5 desviaciones estándar con respecto a la media de la variable.

Con la alineación en el tiempo y la eliminación de datos atípicos se procede al análisis estadístico.

3.2.3 Análisis estadístico

En esta sección se presenta un reporte estadístico de las variables de proceso y calidad. Los estadísticos que se muestran son: media, desviación estándar, valor máximo y valor mínimo. La Tabla 3-4 contiene los valores determinados para cada variable.

En las Figuras 3-2 a 3-6 se muestran las gráficas de operación de las variables de proceso y calidad, junto con los límites superiores e inferiores, cuyos valores corresponden a una desviación estándar sobre la media de cada variable. Las líneas inter-puntadas de color rojo representan los valores de la base de datos sin procesar. Las líneas en azul son los datos que se utilizarán en la modelación de las variables de calidad; es decir son las muestras con alineación en el tiempo y sin datos atípicos.

Tabla 3-4. Estadísticos de las variables de proceso y calidad

Proceso	Variable	Valor medio(μ)	Desviación estándar	Valor máximo	Valor mínimo
Alimentación Premolienda	Clinker G3	47.61	2.65	53.80	42.30
	Yeso G11	2.45	0.32	3.20	1.90
	Caliza	3.86	0.71	5.40	2.30
	Puzolana Seca	15.57	1.07	18.0	12.0
	Tonelada/hora	57.19	7.13	72.0	48.0
Premolienda	Amperaje triturador	155.81	5.01	172.0	145.0
	Vibración triturador	2.38	0.85	3.60	0.6
	Amperaje elevador	39.37	0.73	41.0	38.0
	Presión diferencial colector	3.25	0.17	3.50	2.70
	Presión bomba hidráulica	643.28	27.22	713.0	584.0
	Amperaje motor vent cole	43.88	0.59	45.0	43.0
	Llenado silo	78.54	9.08	95.0	58.0
G20	Amperaje del Motor	313.59	5.01	323.0	304.0
	Temperatura. Cojinete norte	34.79	1.27	37.0	31.0
	Temperatura cojinete sur	45.0	1.33	48.0	42.0
	Temperatura piñón norte	57.17	1.93	58.0	49.0
	Temperatura piñón sur	51.27	1.81	54.0	47.0
	Temperatura material salida	95.49	6.25	107.0	84.0
	Temperatura salida molino	90.96	6.43	103.0	81.0
	Grado llenado cámara 1	74.90	10.05	94.0	46.0
	Grado llenado cámara 2	69.85	7.49	85.0	46.0
	Alimentación molino	65.69	2.29	73.0	57.0
G35	Variador potencia	24.96	1.66	28.0	21.0
	Consigna de velocidad	72.53	0.61	73.0	71.0
	Velocidad	211.66	1.72	213.0	207.0
	Retorno material	82.56	13.76	113.0	52.0
Transporte	Amperaje elevador G31	40.80	2.89	53.0	31.0
	Amperaje elevador G47A	22.11	2.55	34.0	20.0
	Amperaje bomba G47	67.10	15.06	106.0	41.0
G39	Potencia del Motor	194.98	4.66	205.0	180.0
	Consigna de Velocidad	94.62	0.60	96.0	92.0
	Velocidad	1127.53	7.02	1144.0	1097.0
G24	Presión diferencial G24	108.13	35.42	192.0	50.80
	Consigna de velocidad	100	0.00	100	100.0
Secador de puzolana	Temperatura	58.4	10.76	84.0	41.0
	Alimentación puzolana	21.38	2.94	27.50	10.0
	Amperaje elevador	6.94	0.44	8.50	5.70
	Presión diferencial colector	-4.92	1.02	-0.40	-7.00
	Porcentaje en Silo	73.76	14.97	99.0	39.0
Calidad en Molino de Cemento	Temperatura	95.41	6.07	107	84.0
	Blaine	4119.78	112.16	4407.85	3858.22
	Fineza Ret Malla325	4.01	0.58	5.20	2.70
	Óxido de Calcio (CaO)	52.79	0.66	54.50	51.10
	SO3	2.15	0.13	2.38	1.90

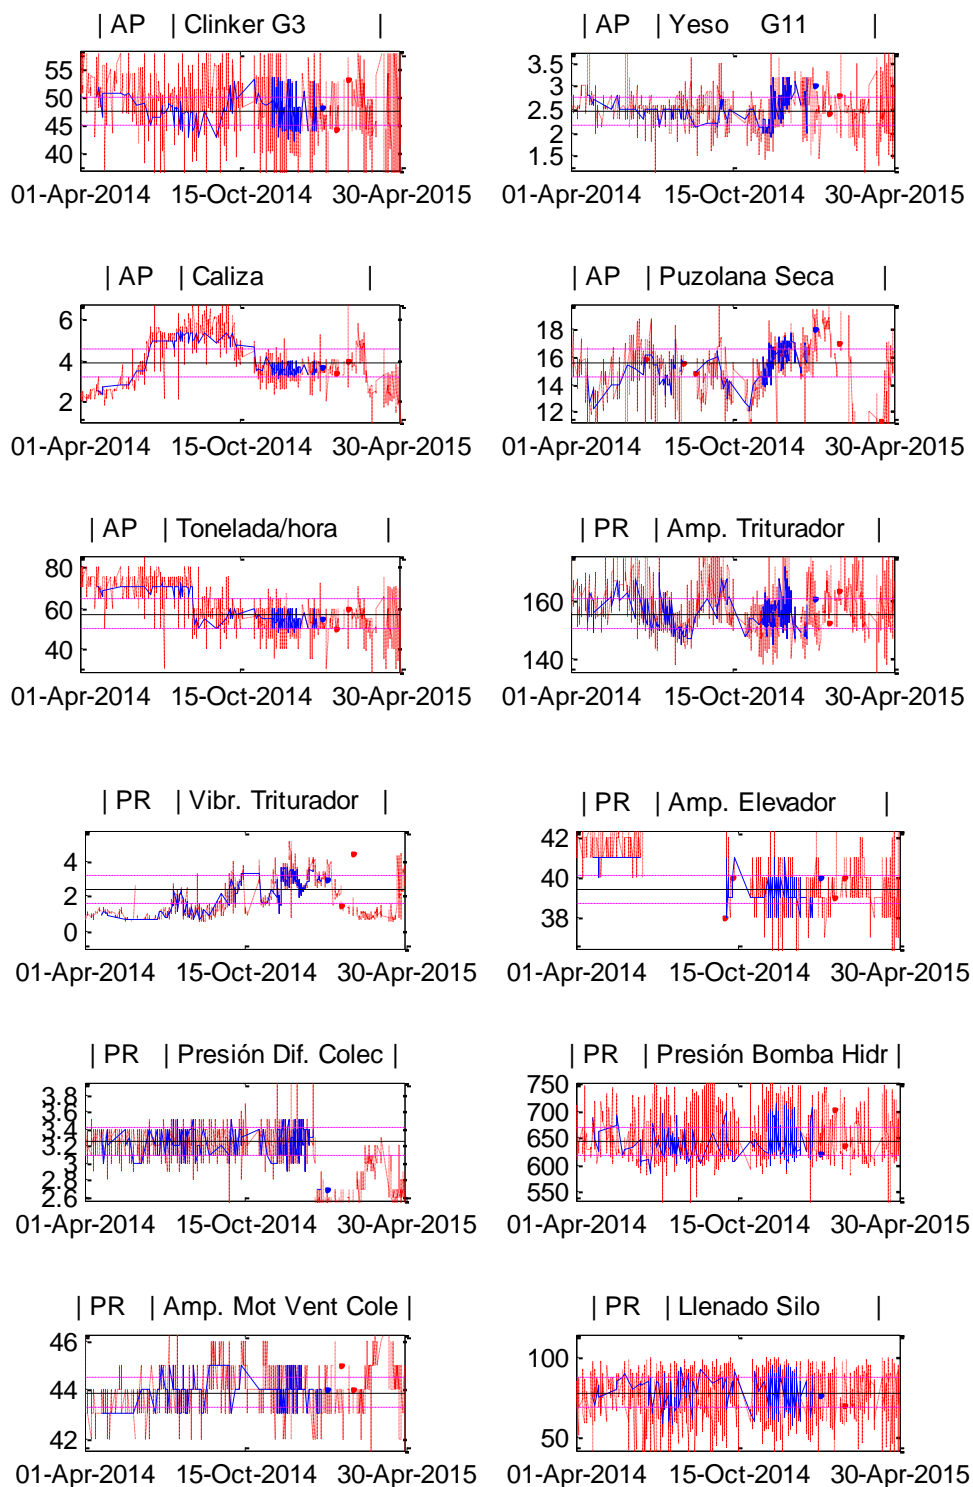


Figura 3-2. Curva de operación de las variables de proceso

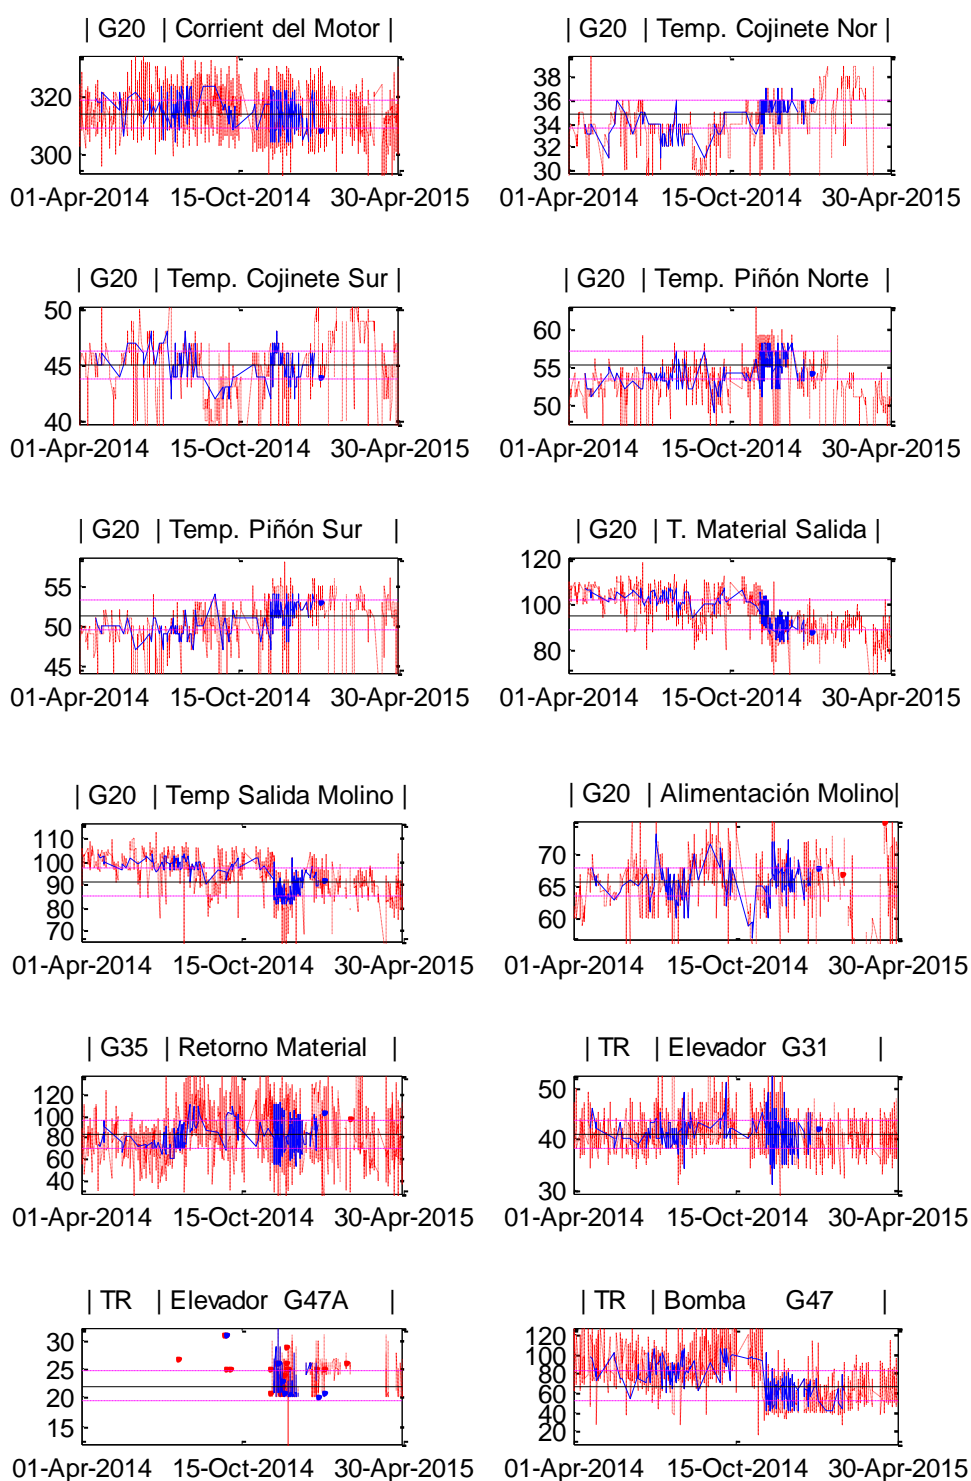


Figura 3-3. Curvas de operación de las variables de proceso

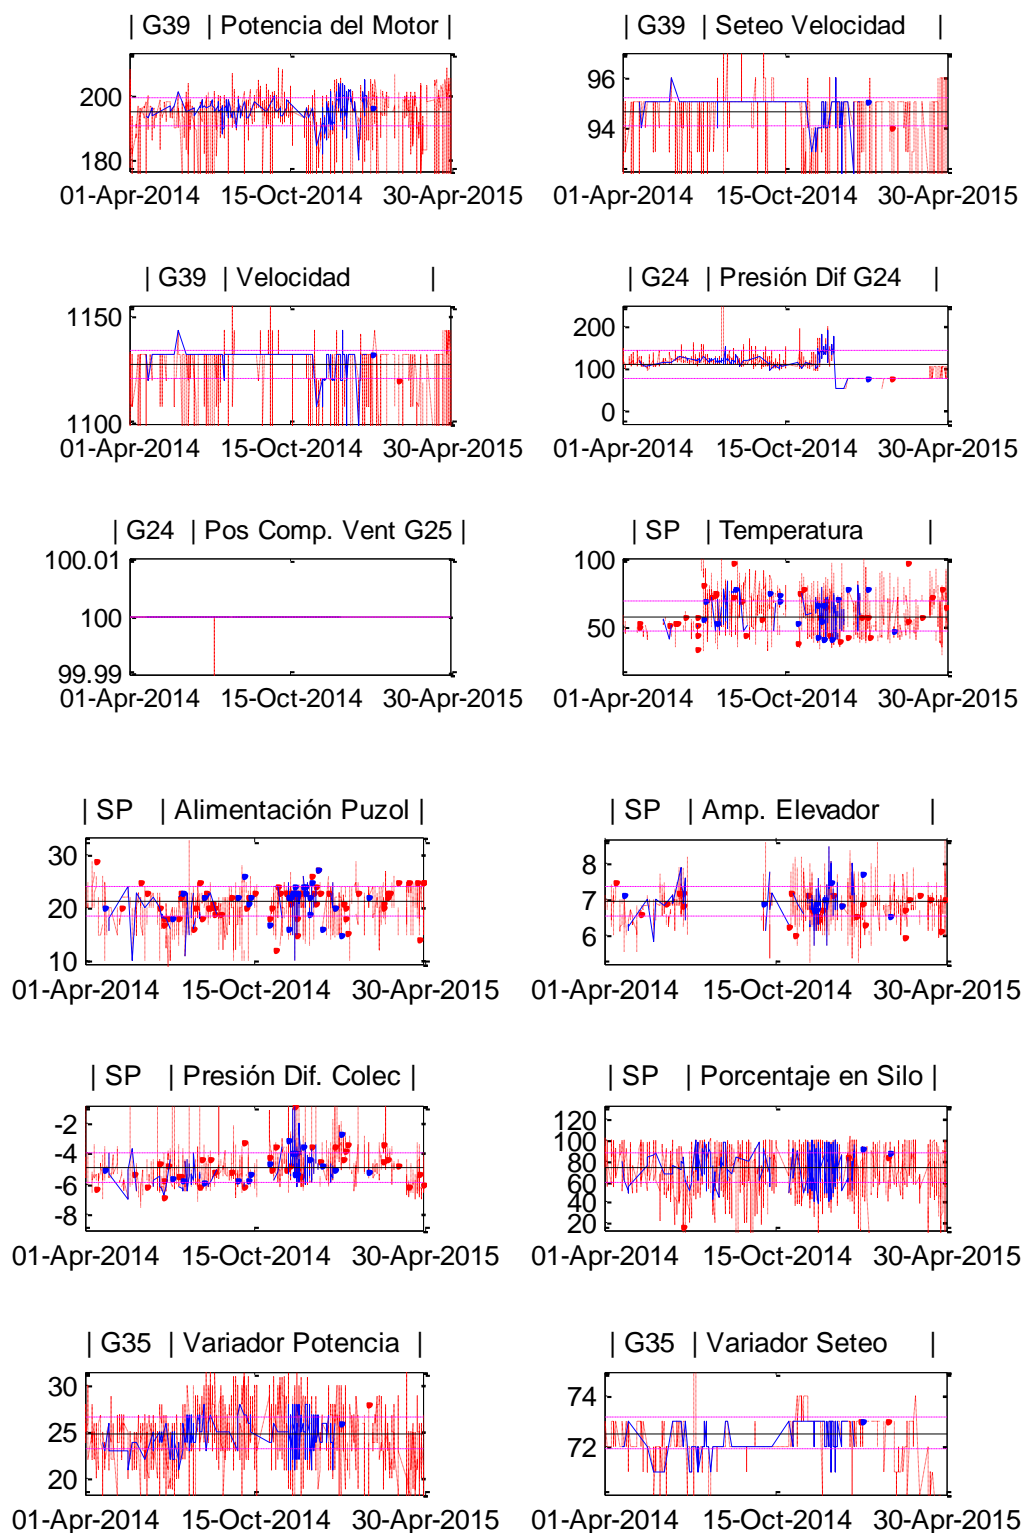


Figura 3-4. Curvas de operación de las variables de proceso

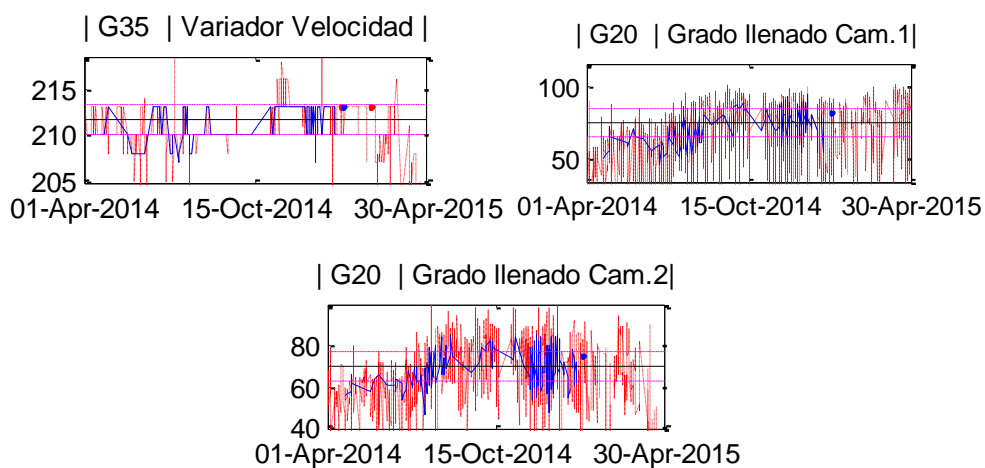


Figura 3-5. Curva de operación de las variables de proceso

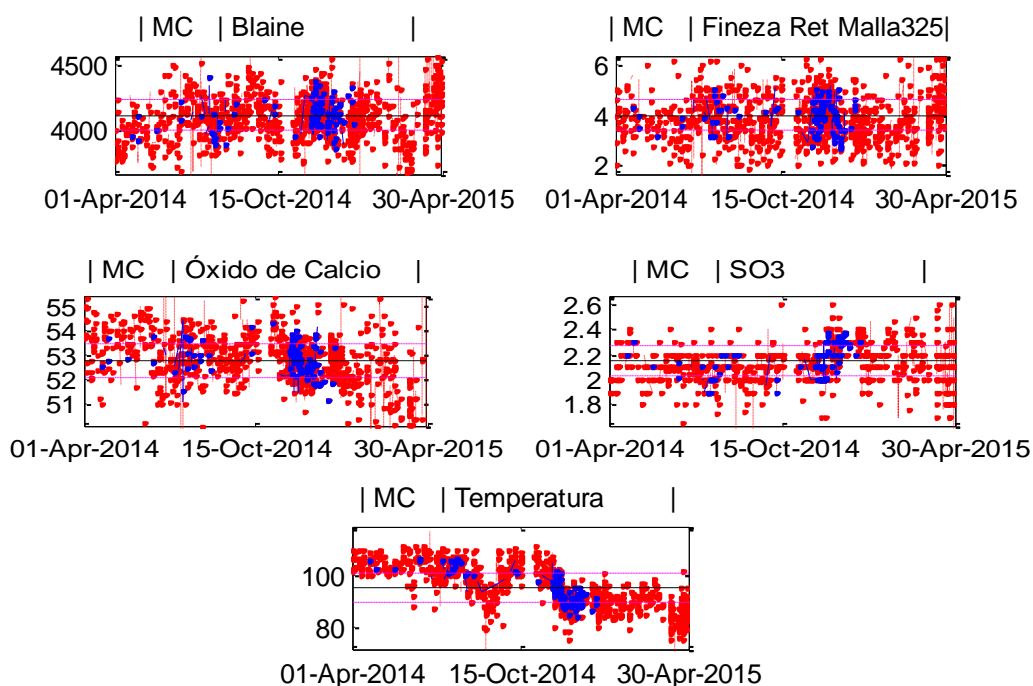


Figura 3-6. Curva de operación de las variables de calidad

Se observa una gran incertidumbre en las variables de proceso y calidad. En un sistema controlado se presentan variaciones menos violentas y de menor magnitud, contrario a lo que encontramos en la planta UCEM.

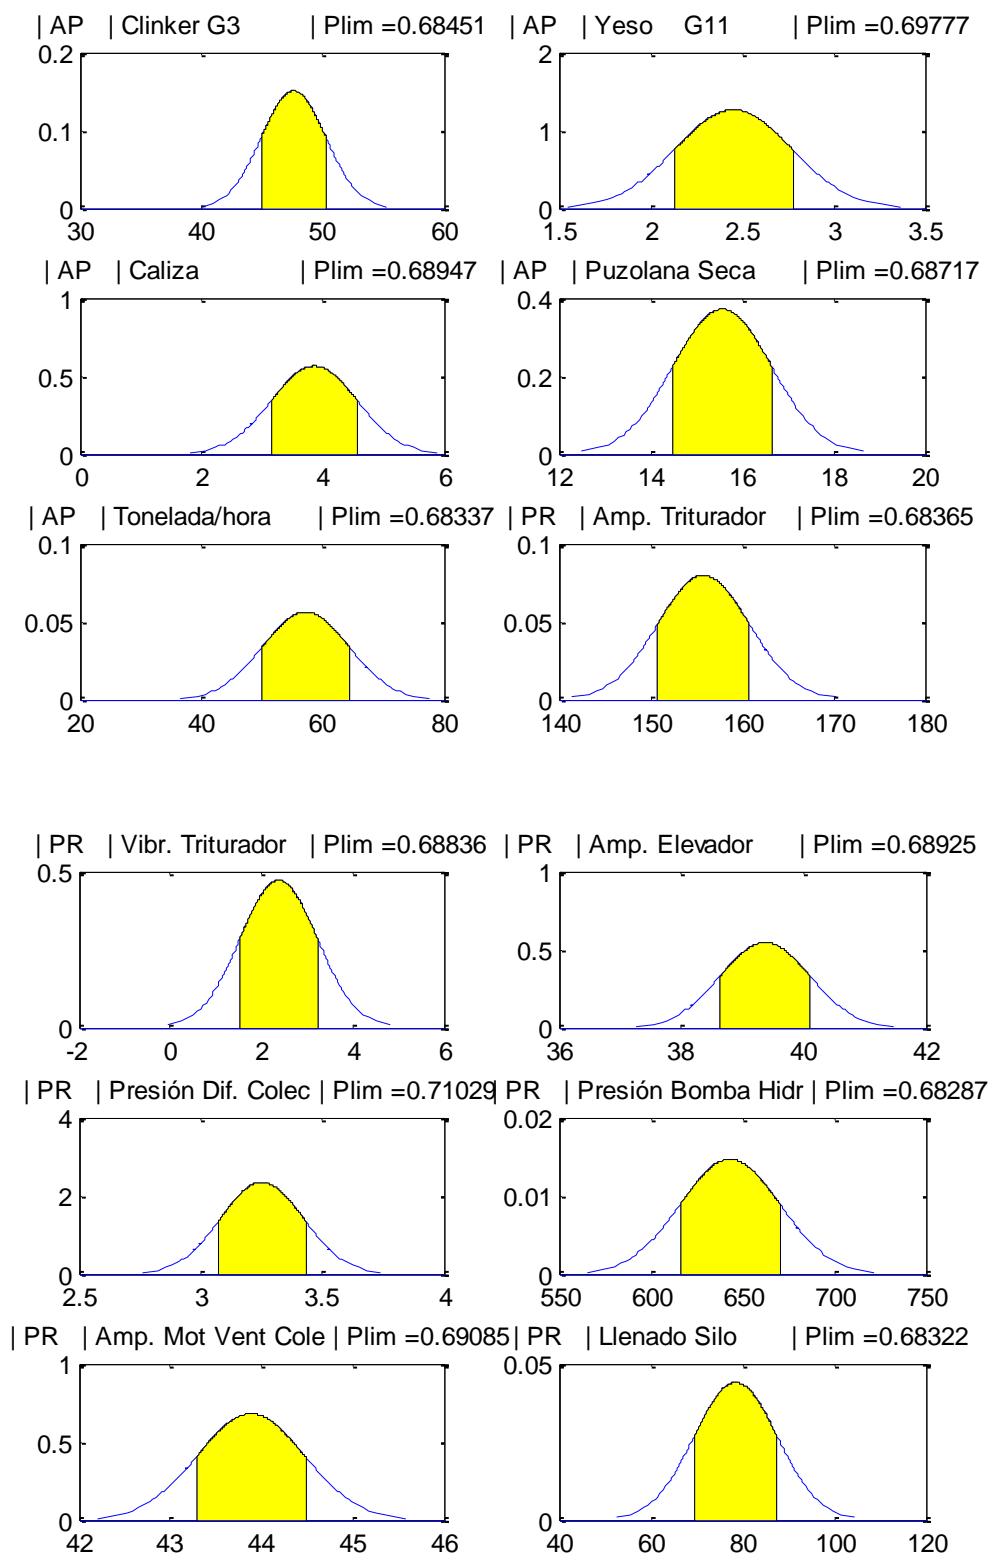


Figura 3-7. Gráficas de capacidad de las variables de proceso

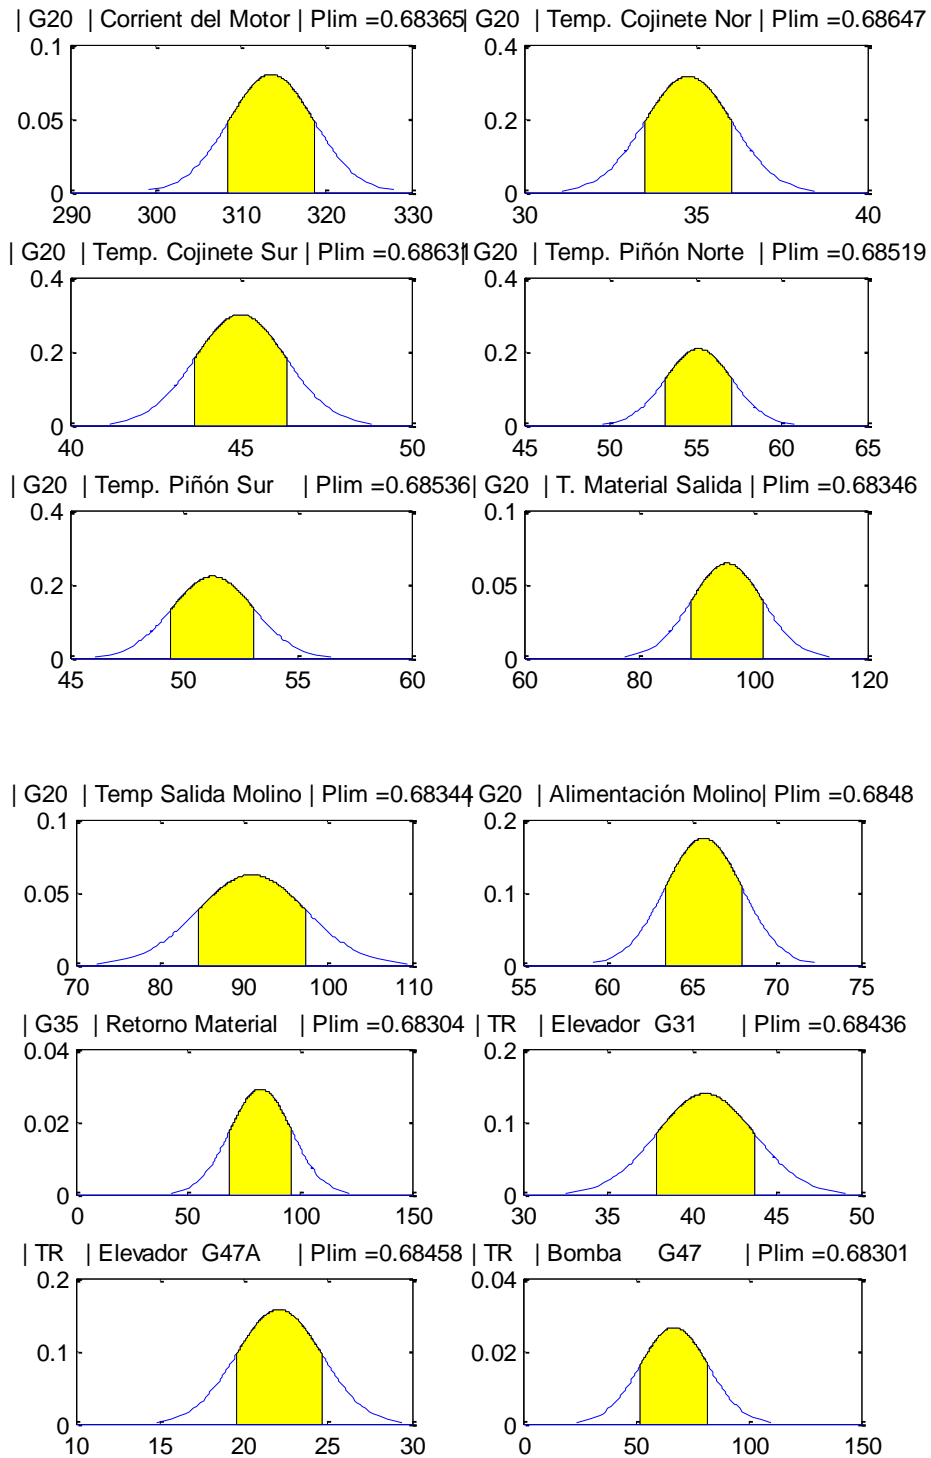


Figura 3-8. Gráficas de capacidad de las variables de proceso

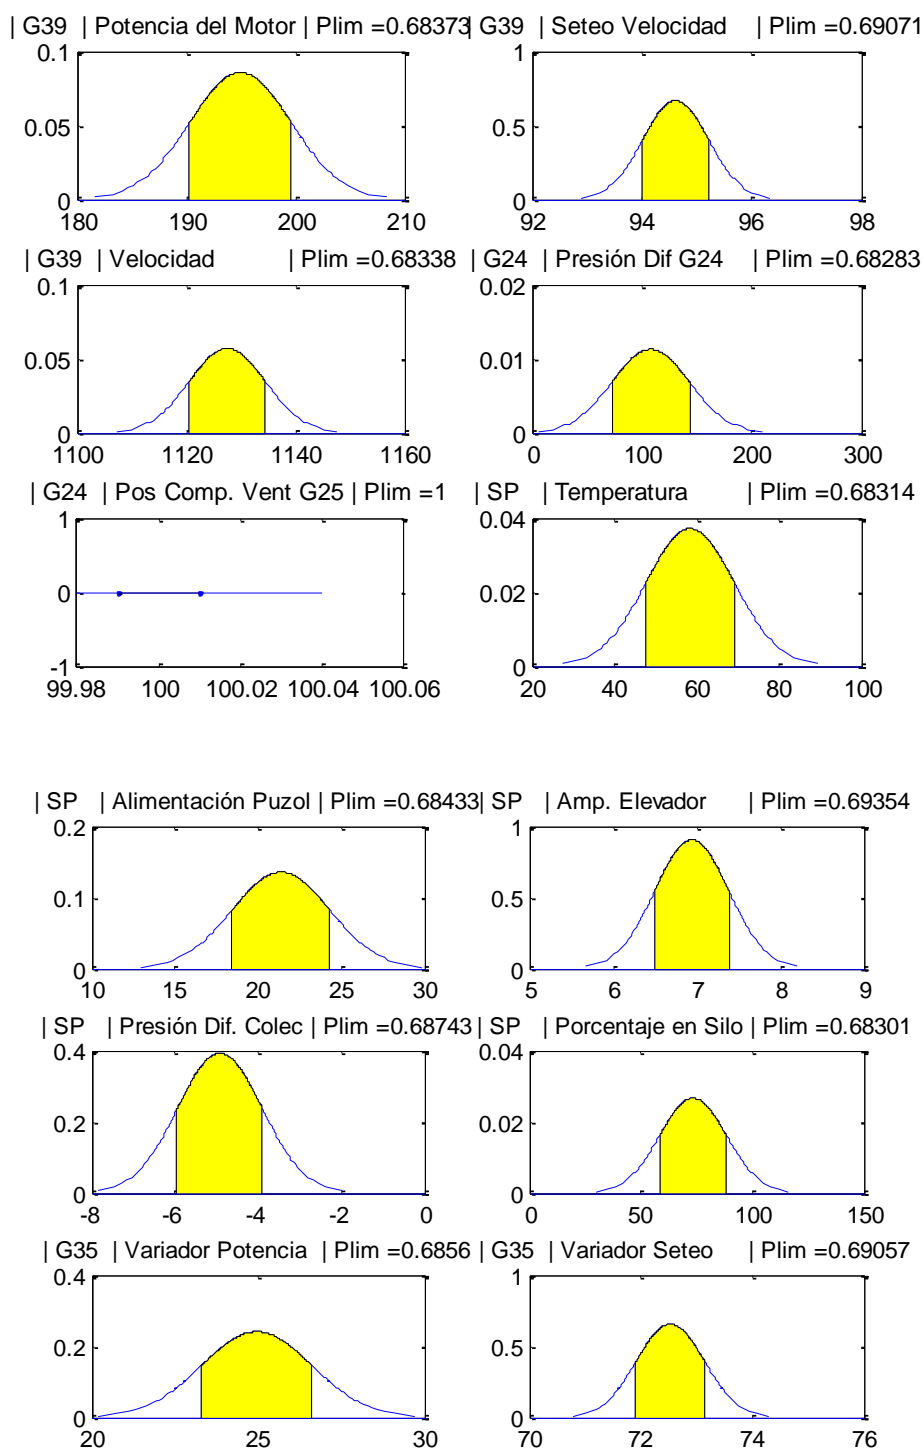


Figura 3-9. Gráficas de capacidad de las variables de proceso




Figura 3-10. Gráficas de capacidad de las variables de proceso

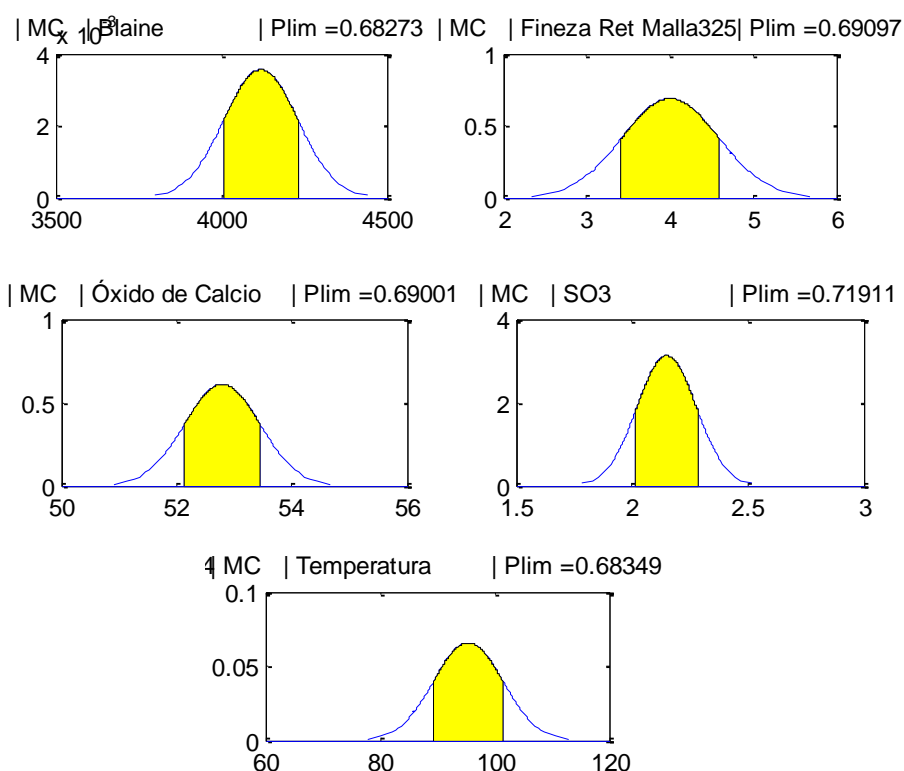


Figura 3-11. Gráficas de capacidad de las variables de calidad

En las Figuras 3-7 a 3-11 se muestra las gráficas de capacidad para las variables de proceso y calidad. Estas figuras muestran distribuciones de probabilidad estimadas para nuevas observaciones y la probabilidad de que una nueva observación se ubique en el intervalo de operación ($\mu \pm \sigma$). Se asumen distribuciones normales en las variables, con media y varianza desconocidas.



Las gráficas de capacidad verifican que los datos de las variables de proceso y calidad provienen de una distribución aproximadamente normal, centrados en el objetivo $\mu \pm \sigma$. La probabilidad de que las nuevas observaciones estén dentro del intervalo 2σ (normalmente este intervalo es 6σ , lo que incrementaría la probabilidad) es mayor a 0.6 para todas las variables de proceso y calidad; esto significa que el proceso es capaz, es decir sus valores fluctúan alrededor de un valor central (lo que se conoce como fluctuación natural del proceso) y dentro del rango especificado. En el presente trabajo, el rango de fluctuación es restringido a 3σ , con lo cual se asegura que los procesos generados por todas las variables sean capaces.

3.2.4 Pre-selección de las variables de modelación

En esta sección se presenta una pre-selección de las variables de proceso y eliminación de las variables de calidad que no se modelarán.

El proceso de selección implica la eliminación de variables que no aportan información útil para la modelación.

Las variables de calidad: temperatura de cemento, óxido de calcio y SO_3 se separan del análisis debido a que no son de interés para la modelación en el presente trabajo.

El primer criterio de eliminación de las variables de proceso es verificar si la variable no presenta una desviación estándar significativa, de ser así será descartado debido a que no aporta información sobre la variabilidad del sistema.

Por otra parte, los cambios de la variable de proceso deben ser moderados; variables que cambien muy rápido entre valores extremos pueden hacer que el modelo resulte con alta incertidumbre.

Adicionalmente, una característica esencial de la variable de proceso seleccionada es contar con un número suficiente de muestras, de modo que en la modelación puede considerarse el máximo posible de condiciones para lograr un ajuste eficiente del modelo, no limitado a una cantidad mínima de eventos.

En este orden de ideas, resulta indispensable discriminar las variables que serán candidatos a formar parte del modelo. En la Tabla 3-5 se muestran las variables de proceso que se eliminan de la modelación de acuerdo a las diferentes razones indicadas en la misma tabla.

Tabla 3-5. Variables de proceso y calidad no consideradas en la modelación

Variable Eliminada	Causa de la Eliminación
AP Caliza	Presentan transiciones muy grandes en los valores de sus muestras.
AP Tonelada Hora	
AP Puzolana Seca	
PR Vibr. Triturador	
PR Amp. Elevador	
G20 Temp. Cojinete Norte	
G20 T. Material Salida	
TR Bomba G47	Se presenta invariante en el tiempo
G24 Presión Dif. G24	
G24 Pos Comp. Vent G25	Tienen número reducido de muestras
SP Temperatura	
TR Elevador G47	
PR Amp. Triturador	Variables de calidad no modeladas
MC Temp_Cem	
MC Óxido de Calcio	
MC SO ₃	

Las variables de proceso eliminadas: por tener una alta incertidumbre, por no presentar variación significativa en sus valores o por no disponer de suficiente número de muestras, se pueden verificar en las Figuras 3-2 a 3-6.

La Tabla 3-6 muestra las variables de proceso y calidad pre-seleccionadas para el proceso de modelación.

Tabla 3-6. Variables de proceso y calidad pre-seleccionadas

Equipo	Variable	Notación
Alimentación	Clinker G3	AP Clinker G3
	Yeso G11	AP Yeso G11
Premolienda	Presión diferencial colector	PR Presión Dif. Colec
	Presión bomba hidráulica	PR Presión Bomba Hidr
	Amperaje motor vent cole	PR Amp. Mot Vent Cole
	Llenado silo	PR Llenado Silo
G20	Amperaje del Motor	G20 Corrient del Motor
	Temperatura cojinete sur	G20 Temp. Cojinete Sur
	Temperatura piñón norte	G20 Temp. Piñón Norte
	Temperatura piñón sur	G20 Temp. Piñón Sur



	Temperatura salida molino	G20	Temp Salida Molino
	Grado llenado cámara 1	G20	Grado llenado Cam.1
	Grado llenado cámara 2	G20	Grado llenado Cam.2
	Alimentación molino	G20	Alimentación Molino
G35	Variador potencia	G35	Variador Potencia
	Consigna de velocidad	G35	Variador Seteo
	Velocidad	G35	Variador Velocidad
	Retorno material	G35	Retorno Material
Transporte	Amperaje elevador G31	TR	Elevador G31
G39	Potencia del Motor	G39	Potencia del Motor
	Consigna de Velocidad	G39	Seteo Velocidad
	Velocidad	G39	Velocidad
Secador de puzolana	Alimentación puzolana	SP	Alimentación Puzol
	Amperaje elevador	SP	Amp. Elevador
	Presión diferencial colector	SP	Presión Dif. Colec
	Porcentaje en Silo	SP	Porcentaje en Silo
Calidad en molino de cemento	Blaine	MC	Blaine
	Fineza Ret Malla325	MC	Fineza Ret Malla325

Con 26 variables de proceso y 2 variables calidad se procede a seleccionar las variables de modelación.

3.3 Selección de las variables de modelación

En esta sección se presenta la fase de selección de las variables de proceso para la modelación de las variables de calidad: Blaine y fineza de retenido de malla No. 325.

Aunque las técnicas estadísticas presentadas al inicio del Capítulo 2 se utilizan para seleccionar las variables que deben considerarse en el modelo, es necesario conocer el proceso que se está modelando con el fin de decidir correctamente que variables añadir o quitar del modelo.

Por ejemplo, es posible que una variable explique significativamente la variable dependiente, pero puede ser que obtener muestras de esta variable implique altos costos o sea muy difícil realizar las mediciones.

En el modelamiento de las variables de calidad de fineza del cemento, existen variables de proceso que se incluyen necesariamente al estar directamente relacionados con la operación del molino de cemento. Éstas se excluyen de la selección mediante indicadores estadísticos y se añaden por defecto en los modelos que se plantean. En la siguiente subsección se indica cuáles son estas variables.

Para la selección de variables de proceso adicionales se realiza un análisis de correlación lineal entre éstas y las variables de calidad. También se construye la matriz de correlación con el objeto de evitar la multicolinealidad entre las variables de proceso.

Finalmente se presentan el cuadro de las variables de proceso seleccionadas para la modelación del Blaine y la fineza de retenido de malla.

3.3.1 Variables de proceso incluidas por defecto en la modelación

Las variables que se presentan en la Tabla 3-7 se incluyen necesariamente en los modelos estadísticos (independientemente de su coeficiente de correlación con la variable de calidad que se modela) debido a que están directamente relacionados con el proceso de molino de cemento y son determinantes en la calidad del producto de salida [7].

Tabla 3-7. Variables de proceso incluidas por defecto

Variable de proceso	
G20	Alimentación Molino
G39	Seteo Velocidad
G35	Retorno Material
G35	Variador Seteo

3.3.2 Proceso de selección de las variables de modelación



La selección de las variables de proceso adicionales que se incluirán en la modelación del Blaine y la fineza de retenido de malla No. 325 se realiza de acuerdo al siguiente procedimiento:

Paso 1. Determinar los coeficientes de correlación simple r entre la variable de calidad y las variables de proceso. Separar las diez primeras variables con la más alta correlación.

Paso 2. Obtener la matriz de correlación R y determinar el *valor-p* para cada par de variables de proceso separadas. Obtener los pares de variables con coeficientes de correlación significativos. Estos pares se consideran colineales, y son aquellos cuyo *valor-p* sea menor que 0.001 (con un intervalo de confianza del 99.999%).

Paso 3. Seleccionar, de las variables de proceso separadas en el Paso 1, las variables no colineales los cuáles se verifican de acuerdo al Paso 2. Se eliminan de cada par de variables colineales la variable con menor r (coeficiente de correlación lineal simple) respecto de la variable de calidad.

El total de variables de proceso para la modelación es de diez como máximo incluyendo las variables expuestas en la Tabla 3-7.

3.3.3 Variables de proceso para el modelo del Blaine

Las variables de proceso obtenidas de acuerdo al Paso 1 de la subsección anterior se presentan en la Figura 3-12.

En la matriz de correlación se determina la multicolinealidad entre los pares de variables de la Figura 3-12, y de acuerdo al Paso 3 de la subsección anterior se determinan las variables para el modelo del Blaine que se muestran en la

Tabla 3-8.

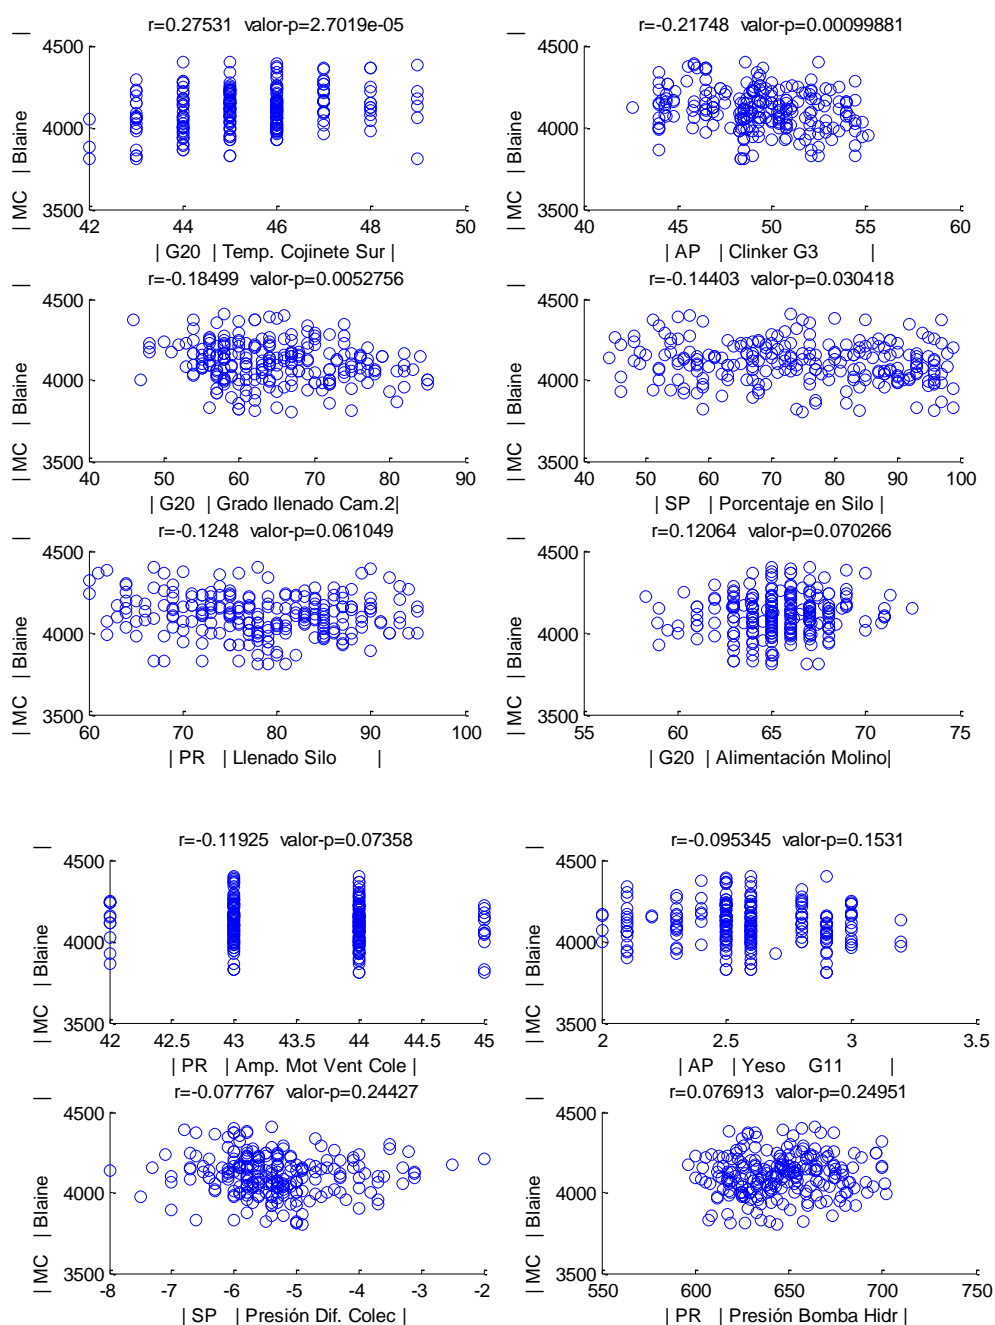


Figura 3-12. Variables de proceso altamente correlacionadas con el Blaine

Tabla 3-8. Variables de proceso para el modelo del Blaine

Variable seleccionada	
G20	Alimentación Molino
G39	Seteo Velocidad
G35	Retorno Material
G35	Variador Seteo
G20	Temp. Cojinete Sur
AP	Clinker G3
PR	Llenado Silo



3.3.4 Variables de proceso para el modelo del retenido de malla No. 324

De acuerdo al Paso 1 presentado en la subsección 0, las variables de proceso seleccionadas se presentan en la Figura 3-13.

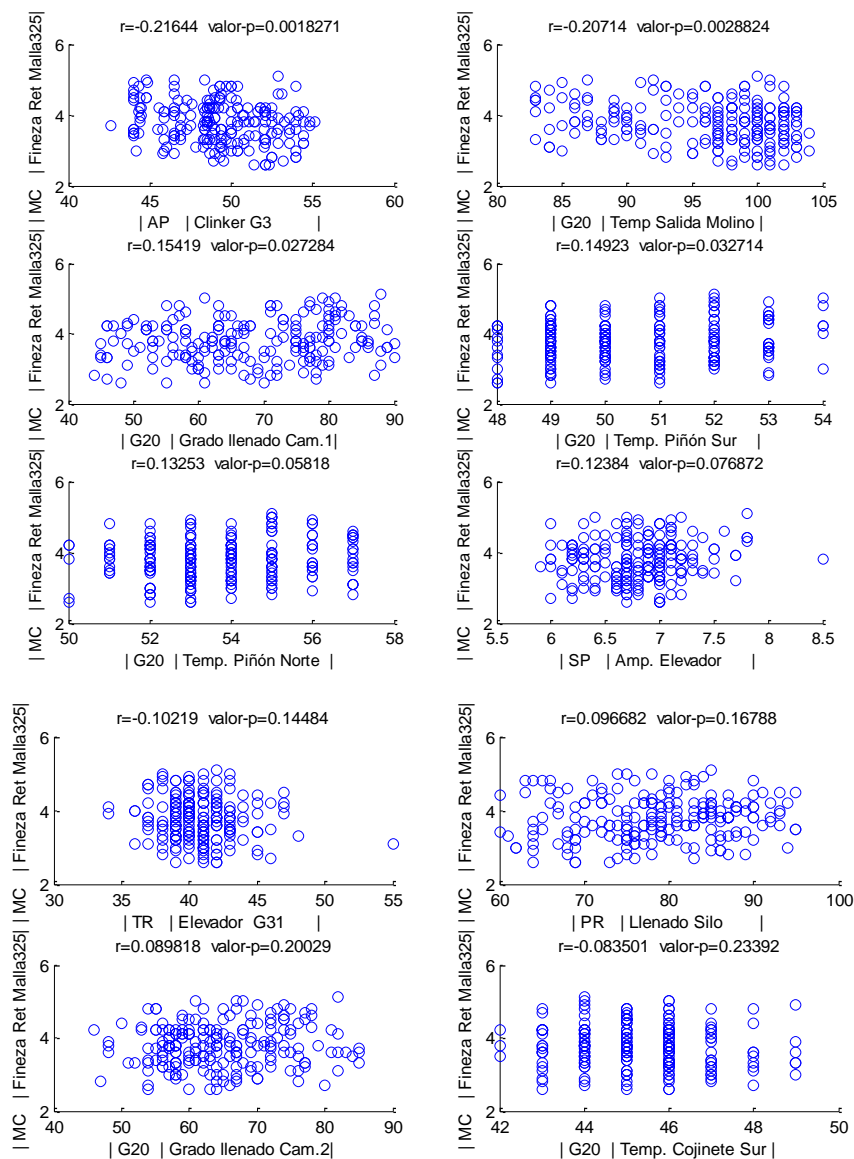


Figura 3-13. Variables de proceso altamente correlacionados con el retenido de malla No. 325

En la matriz de correlación se determina la multicolinealidad entre los pares de variables de la Figura 3-13, y acuerdo al Paso 3 de la sección 0 se determinan las variables para el modelo del retenido de malla No. 325 que se muestran en la Tabla 3-9.

Tabla 3-9. Variables de proceso para el modelo del retenido de malla No. 325

Variable seleccionada	
G20	Alimentación Molino
G39	Seteo Velocidad
G35	Retorno Material
G35	Variador Seteo
AP	Clinker G3
G20	Temp Salida Molino
TR	Elevador G31

3.4 Muestras disponibles para la modelación

Luego del pre-procesamiento de los datos y la eliminación de datos no numéricos se disponen de 221 muestras para la modelación del Blaine y 200 muestras para la modelación de la fineza de retenido de malla No. 325. Estos datos corresponden al periodo comprendido entre el 01/04/2015 y el 30/04/2015, excluyendo los datos del mes de enero que se utilizarán para la validación con nuevo conjunto de datos.

3.5 Identificación y estandarización de las variables de regresión

Las variables de proceso seleccionadas para el modelamiento del Blaine y el retenido de malla No. 325 se identifican en la Tabla 3-10.

Además la Tabla 3-10 contiene el identificador de la variable de proceso estandarizada. La estandarización permite que las variables de regresión sean comparables, ya que están en la misma escala.

La variable se estandariza restando de su valor la media y dividiendo este resultado entre la varianza de la variable:

$$z_i = \frac{x_i - \bar{x}}{\sigma_x} \quad (3-1)$$

donde, z es la variable x estandarizada, \bar{x} y σ_x son la media y la varianza de x respectivamente.

Tabla 3-10. Identificación de las variables de regresión

Variables del modelo del retenido de malla No. 325		Variables del modelo del Blaine		ID de la variable de proceso	ID de la variable estandarizada
AP	Clinker G3	AP	Clinker G3	x_1	z_1
TR	Elevador G31	PR	Llenado Silo	x_2	z_2
G20	Temp Salida Molino	G20	Temp cojinete sur	x_3	z_3
G35	Variador Seteo	G35	Variador Seteo	x_4	z_4
G35	Retorno Material	G35	Retorno Material	x_5	z_5
G39	Seteo Velocidad	G39	Seteo Velocidad	x_6	z_6
G20	Alimentación Molino	G20	Alimentación Molino	x_7	z_7

Los identificadores presentados en la Tabla 3-10 se utilizarán en la modelación estadística y la exposición de los modelos resultantes.

3.6 Modelos estadísticos

En esta sección se presentan los modelos estadísticos para las variables de calidad de Blaine y del retenido de malla No. 325.

Los modelos desarrollados son: modelos cortos con combinaciones de las variables de proceso seleccionados y modelos largos con introducción de la combinación de las variables de básicas y variables básicas en segundo orden.

Además se desarrolla un modelo estadístico de segundo orden con transformación Box-Cox de la variable dependiente.

Se analizan la bondad de ajuste de cada modelo a los datos experimentales, que incluye análisis de residuos.

Finalmente se analiza el intervalo de confianza y la capacidad de predicción del modelo.

3.6.1 Proceso de modelación estadística

La modelación estadística se realiza de acuerdo al siguiente procedimiento:

Paso 1. Estandarización de las variables de regresión. Este proceso asegura que la hipótesis de normalidad de las variables de regresión se cumpla.

Paso 2. Se plantea un modelo base de partida. A través de la técnica *stepwise* (utilizando el método *stepwiselm()* de *MATLAB*) se determinan las variables de regresión que se añaden o quitan del modelo base inicial. Para cada variable seleccionada por el método *stepwise*, en el modelo resultante, se determinan los coeficientes de regresión β a través de la técnica de los mínimos cuadrados.

Paso 3. Verificar la bondad de ajuste del modelo desarrollado. Las estadísticas utilizadas son: *RMSE*(raíz cuadrada del error cuadrático medio) r^2 , $r^2_{ajustado}$, la estadística F y su *valor - p*.

Paso 4. Análisis de residuos. Se verifica la hipótesis de normalidad del residuo mediante las gráficas de probabilidad normal y residuos tipificados y se realiza la prueba de Anderson-Darling. Se verifica, además que los residuos no estén autocorrelacionados mediante la prueba de Durbin-Watson.

Paso 5. Se presenta el intervalo de confianza del modelo. Además se determina la capacidad de predicción del modelo mediante el estadístico PRESS.

En el caso del modelo con transformación Box-Cox de la variable dependiente, se incluye el proceso de transformación (utilizando el método *boxcox()* de *MATLAB*) en el Paso 1 y la transformación inversa antes del Paso 4.

3.6.2 Modelos de regresión lineal múltiple de las variables de calidad

Los modelos de regresión lineal múltiple que se presentan son: modelo corto, modelo largo y modelo largo con transformación Box-Cox de la variable dependiente.

3.6.2.1 Modelos del Blaine

Se plantean tres modelos para el Blaine, se identifican sus ecuaciones y se analizan la bondad de ajuste.

3.6.2.1.1 Modelo corto

Siguiendo el proceso de modelación estadística, el modelo base corto es:

(3-2)

$$\text{Blaine}_{mbc} = 1 + z1 + z2 + z3 + z4 + z5 + z6 + z7$$

El modelo corto obtenido con el método *stepwise* es:

(3-3)

$$\text{Blaine}_{mc} = 4106.6 + 18.516 * z1 * z4 - 15.777 * z2 * z4 + 19.578 * z3 * z6$$

Las estadísticas de la bondad de ajuste del modelo son:

$$RMSE_{mc} = 83.4, r_{mc}^2 = 0.214, r_{adj_{mc}}^2 = 0.179, F_{mc} = 6.03; \text{valor} - p = 7.53e - 07$$

El ajuste del modelo a los datos experimentales no es bueno.

En la Figura 3-14, se muestra la gráfica de probabilidad normal y la gráfica del residuo tipificado.




Figura 3-14. Gráfico de probabilidad normal y residuos tipificados del modelo corto del Blaine

El *valor-p* de la prueba de Anderson-Darling es de 0.003. Con un nivel de significancia del 1%, el test sugiere que la distribución del residuo no es normal. Los gráficos de normalidad del error, muestran que éste sigue una distribución aproximadamente normal.

El estadístico Durbin-Watson es 1.9749, lo que indica que el error no está autocorrelacionado.

En la Figura 3-15 se observa el ajuste obtenido del modelo a los datos experimentales y el intervalo de confianza del 95%.




Figura 3-15. Ajuste del modelo corto de regresión lineal múltiple para el Blaine

El modelo no es bueno; los valores experimentales están fuera del intervalo de confianza.

El estadístico PRESS obtenido para este modelo es:

$$PRESS_{mc} = 1.3502e + 06; R^2_{predic_{mc}} = 0.1388$$

La capacidad de predicción del modelo es muy baja.

3.6.2.1.2 Modelo largo de segundo orden

En este modelo se plantea incluir las variables de regresión en segundo orden con el objetivo de mejorar la bondad de ajuste obtenido por el modelo corto.

El modelo base largo es:



$$\begin{aligned} \text{Blaine}_{\text{mbl}} = & 1 + z_1 + z_2 + z_3 + z_4 + z_5 + z_6 + z_7 + z_1 * z_2 + z_1 * z_3 + z_1 * z_4 \\ & + z_1 * z_5 + z_1 * z_6 + z_1 * z_7 + z_2 * z_3 + z_2 * z_4 + z_2 * z_5 + z_2 \\ & * z_6 + z_2 * z_7 + z_3 * z_4 + z_3 * z_5 + z_3 * z_6 + z_3 * z_7 + z_4 * z_5 \\ & + z_4 * z_6 + z_4 * z_7 + z_5 * z_6 + z_5 * z_7 + z_6 * z_7 + z_1^2 + z_2^2 \\ & + z_3^2 + z_4^2 + z_5^2 + z_6^2 + z_7^2 \end{aligned} \quad (3-4)$$

El modelo largo de segundo orden obtenido con el método *stepwise* es:

$$\begin{aligned} \text{Blaine}_{\text{ml}} = & 4112.7 + 24.053 * z_1 * z_3 + 18.591 * z_1 * z_4 + 14.003 * z_1 * z_5 \\ & - 25.377 * z_2 * z_3 - 13.177 * z_2 * z_4 + 13.241 * z_2 * z_6 \\ & - 11.84 * z_3 * z_5 + 23.694 * z_3 * z_6 + 10.817 * z_4 * z_6 \\ & + 17.647 * z_4 * z_7 + 15.089 * z_5 * z_7 - 8.0635 * z_1^2 + 38.95 \\ & * z_2^2 - 36.057 * z_5^2 \end{aligned} \quad (3-5)$$

Las estadísticas de la bondad de ajuste del modelo son:

$$RMSE_{ml} = 65.5, \quad r_{ml}^2 = 0.676, \quad r^2_{adj_{ml}} = 0.632, \quad F_{ml} = 15.3; \text{valor} - p = 7.54e - 28$$

El ajuste del modelo a los datos experimentales es bueno. En la Figura 3-16 se muestra la gráfica de probabilidad normal y la gráfica del residuo tipificado de este modelo.

El *valor-p* de la prueba de Anderson-Darling es de 0.015. Con un nivel de significancia del 1%, el test sugiere que la distribución del residuo es normal. Los gráficos de normalidad del error, demuestran que éste sigue una distribución normal.

El estadístico Durbin-Watson es 2.048, lo que indica que el error no está autocorrelacionado.




Figura 3-16. Gráfico de probabilidad normal y residuos tipificados del modelo largo de segundo orden del Blaine

En la Figura 3-17 se observa el ajuste obtenido del modelo a los datos experimentales y el intervalo de confianza del 95%.




Figura 3-17. Ajuste del modelo largo de segundo orden para el Blaine

El modelo es muy bueno; los valores de las predicciones son muy aproximados a los experimentales.



El estadístico PRESS obtenido para este modelo es:

$$PRESS_{ml} = 8.3321e + 05; R^2_{predic_{ml}} = 0.5907$$

La capacidad de predicción del modelo es alta.

3.6.2.1.3 Modelo de segundo orden con transformación Box-Cox del Blaine

En este modelo se plantea, además de incluir las variables de regresión en segundo orden, realizar la transformación no lineal Box-Cox a los datos del Blaine. El objetivo de la transformación es obtener la correlación lineal más alta posible entre las variables de regresión y el Blaine, lo cual incrementaría la bondad de ajuste del modelo.

El modelo base largo es el mismo de la ecuación (3-4). En la transformación Box-Cox se determina $\lambda_b = 2.1443$.

El modelo, de segundo orden y con transformación Box-Cox del Blaine, obtenido con el método *stepwise* es:

$$\begin{aligned} \text{Blaine}_{\text{Box-Cox}} = & (2.6227e + 07) + (3.2046e + 05) * z1 * z3 + (2.5442e + 05) * z1 \\ & * z4 + (1.9296e + 05) * z1 * z5 - (3.5338e + 05) * z2 * z3 \\ & - (1.8023e + 05) * z2 * z4 + (1.7795e + 05) * z2 * z6 \\ & - (1.5947e + 05) z3 * z5 + (3.1978e + 05) * z3 * z6 \\ & + (1.462e + 05) * z4 * z6 + (2.4305e + 05) * z4 * z7 \\ & + (1.9966e + 05) * z5 * z7 - (1.0794e + 05) z1^2 + (5.3504e + 05) \\ & * z2^2 - (4.8895e + 05) * z5^2 \end{aligned} \quad (3-6)$$

Las estadísticas de la bondad de ajuste del modelo son:

$$RMSE_{b-c} = 8.95e + 05, r^2_{b-c} = 0.674, r^2_{adj_{b-c}} = 0.63, F_{b-c} = 15.2; \text{valor} - p = 1.08e - 27$$

El ajuste del modelo a los datos experimentales es bastante bueno, sin embargo se ve reducido con respecto al modelo largo de segundo orden.

De las predicciones obtenidas con la ecuación (3-6), se debe obtener la transformada inversa Box-Cox, que se realiza según la siguiente ecuación:

(3-7)

$$\mathbf{Blaine}_{inv} = (\mathbf{Blaine}_{\text{Box-Cox}} * \lambda_b + 1)^{\frac{1}{\lambda_b}}$$

con $\lambda_b = 2.1443$. Los valores de \mathbf{Blaine}_{inv} son comparadas con los datos experimentales del Blaine para el análisis de los residuos.

En la Figura 3-18 se muestra la gráfica de probabilidad normal y la gráfica del residuo tipificado de este modelo.




Figura 3-18. Gráfico de probabilidad normal y residuos tipificados del modelo Blaine con transformación Box-Cox

El *valor-p* de la prueba de Anderson-Darling es de 0.0228. Con un nivel de significancia del 1%, el test sugiere que la distribución del residuo es normal. Los gráficos de normalidad del error, demuestran que éste sigue una distribución normal.

El estadístico Durbin-Watson es 2.052, lo que indica que el error no está autocorrelacionado.

En la Figura 3-19 se observa el ajuste obtenido del modelo a los datos experimentales y el intervalo de confianza del 95%.




Figura 3-19. Ajuste del modelo con transformación Box-Cox del Blaine

El modelo es muy bueno; los valores de las predicciones son muy aproximados a los experimentales.

El estadístico PRESS obtenido para este modelo es:

$$PRESS_{b-c} = 8.3330e + 05; R^2_{predic_{b-c}} = 1.0000$$

La capacidad de predicción del modelo es alta.

3.6.2.1.4 Selección del mejor modelo estadístico para el Blaine

Para la validación con el nuevo set de datos únicamente se considerará el modelo largo de segundo orden y el modelo con transformación Box-Cox. El modelo corto se descarta debido a su baja bondad de ajuste.

El modelo preferencial es el de transformación Box-Cox del Blaine ya que su estadístico $R^2_{predic_{b-c}}$ es la mayor, por tanto presenta una mejor predicción.

En la Figura 3-20 se muestra el comportamiento los modelos en la predicción de los datos experimentales.

El modelo largo y el modelo con transformación Box-Cox tienen un ajuste similar.




Figura 3-20. Comparación de los modelos estadísticos del Blaine

3.6.2.2 Modelos del retenido de malla No. 325

Se plantean tres modelos para el retenido de malla No. 325, se identifican sus ecuaciones y se analizan la bondad de ajuste.

3.6.2.2.1 Modelo corto

Siguiendo el proceso de modelación estadística, el modelo base corto para la retenido de malla No. 325, es:

$$\text{Retenido}_{mbc} = 1 + z1 + z2 + z3 + z4 + z5 + z6 + z7$$

(3-8)

El modelo corto obtenido con el método *stepwise* es:

$$\text{Retenido}_{mc} = 3.8332 - 0.063427 * z3 - 0.053282 * z4 - 0.08363 * z5 - 0.20584 * z6 - 0.067423 * z2 * z7 \quad (3-9)$$

Las estadísticas de la bondad de ajuste del modelo son:

$$RMSE_{mc} = 0.314, r_{mc}^2 = 0.4, r_{adj_{mc}}^2 = 0.37 F_{mc} = 13.2; \text{valor} - p = 6.42e - 13$$

El ajuste del modelo a los datos experimentales no es bueno.

En la Figura 3-21 se muestra la gráfica de probabilidad normal y la gráfica del residuo tipificado.




Figura 3-21. Gráfico de probabilidad normal y residuos tipificados del modelo corto del retenido de malla No. 325

El *valor-p* de la prueba de Anderson-Darling es de 0.0130. Con un nivel de significancia del 1%, el test sugiere que la distribución del residuo es normal. Los gráficos de normalidad del error, demuestran que éste sigue una distribución normal.

El estadístico Durbin-Watson es 1.7661, lo que indica que el error no está autocorrelacionado.

En la Figura 3-22 se observa el ajuste obtenido del modelo a los datos experimentales y el intervalo de confianza del 95%.




Figura 3-22. Ajuste del modelo corto de regresión lineal múltiple para el retenido de malla No. 325

El modelo no es bueno; el intervalo de confianza no encierra todos los valores experimentales.

El estadístico PRESS obtenido para este modelo es:

$$PRESS_{mc} = 15.0758; R^2_{predic_{mc}} = 0.3335$$

La capacidad de predicción del modelo es baja.

3.6.2.2.2 Modelo largo de segundo orden



En este modelo se plantea incluir las variables de regresión en segundo orden con el objetivo de mejorar la bondad de ajuste obtenido por el modelo corto.

El modelo base largo es:

$$\text{Retenido}_{\text{mbl}} = 1 + z_1 + z_2 + z_3 + z_4 + z_5 + z_6 + z_7 + z_1 * z_2 + z_1 * z_3 + z_1 * z_4 + z_1 * z_5 + z_1 * z_6 + z_1 * z_7 + z_2 * z_3 + z_2 * z_4 + z_2 * z_5 + z_2 * z_6 + z_2 * z_7 + z_3 * z_4 + z_3 * z_5 + z_3 * z_6 + z_3 * z_7 + z_4 * z_5 + z_4 * z_6 + z_4 * z_7 + z_5 * z_6 + z_5 * z_7 + z_6 * z_7 + z_1^2 + z_2^2 + z_3^2 + z_4^2 + z_5^2 + z_6^2 + z_7^2 \quad (3-10)$$

El modelo largo de segundo orden obtenido con el método *stepwise* es:

$$\begin{aligned} \text{Retenido}_{\text{ml}} = & 3.8096 + 0.14098 * z_1 * z_2 + 0.070462 * z_1 * z_3 + 0.075451 \\ & * z_1 * z_5 + 0.084887 * z_1 * z_6 - 0.085678 * z_2 * z_3 - 0.17174 \\ & * z_2 * z_4 + 0.067356 * z_2 * z_5 + 0.1569 * z_2 * z_6 - 0.21112 * z_2 \\ & * z_7 + 0.14579 * z_3 * z_4 - 0.090265 * z_3 * z_5 + 0.16019 * z_3 \\ & * z_6 - 0.074519 * z_4 * z_6 - 0.048619 * z_5 * z_6 + 0.057795 * z_6 \\ & * z_7 - 0.075229 * z_2^2 + 0.064474 * z_4^2 + 0.035458 * z_5^2 \\ & - 0.11039 * z_6^2 \end{aligned} \quad (3-11)$$

Las estadísticas de la bondad de ajuste del modelo son:

$$RMSE_{\text{ml}} = 0.225, r_{\text{ml}}^2 = 0.799, r^2_{\text{adj}_{\text{ml}}} = 0.752, F_{\text{ml}} = 17.1; \text{valor} - p = 4.93e - 28$$

El ajuste del modelo a los datos experimentales es muy bueno.

La Figura 3-23 muestra la gráfica de probabilidad normal y la gráfica del residuo tipificado de este modelo.




Figura 3-23. Gráfico de probabilidad normal y residuos tipificados del modelo largo de segundo orden del retenido de malla No. 325

El *valor-p* de la prueba de Anderson-Darling es de 0.012. Con un nivel de significancia del 1%, el test sugiere que la distribución del residuo es normal. Los gráficos de normalidad del error, demuestran que éste sigue una distribución aproximadamente normal.

El estadístico Durbin-Watson es 2.1416, lo que indica que el error no está autocorrelacionado.

La Figura 3-24 muestra el ajuste obtenido del modelo a los datos experimentales y el intervalo de confianza del 95%.

El modelo es muy bueno; los valores de las predicciones son muy aproximados a los experimentales.

El estadístico PRESS obtenido para este modelo es:

$$PRESS_{ml} = 8.6373; R^2_{predic_{ml}} = 0.6930$$

La capacidad de predicción del modelo es alta.




Figura 3-24. Ajuste del modelo largo de segundo orden para la fineza de retenido de malla 325

3.6.2.2.3 Modelo de segundo orden con transformación Box-Cox del retenido de malla No. 325

En este modelo, además de incluir las variables de regresión en segundo orden, se realiza la transformación no lineal Box-Cox a los datos del retenido de malla No. 325.

El modelo base largo es el mismo de la ecuación (3-10).

En la transformación Box-Cox se determina $\lambda_f = 1.1129$.

El modelo, de segundo orden y con transformación Box-Cox del retenido de malla No. 325, obtenido con el método *stepwise* es:

(3-12)

Retenido_{Box-Cox}

$$\begin{aligned}
&= 3.0849 + 0.16456 * z_1 * z_2 + 0.082361 * z_1 * z_3 + 0.087702 \\
&* z_1 * z_5 + 0.097914 * z_1 * z_6 - 0.099933 * z_2 * z_3 - 0.19943 \\
&* z_2 * z_4 + 0.07858 * z_2 * z_5 + 0.18319 * z_2 * z_6 - 0.24495 \\
&* z_2 * z_7 + 0.16954 * z_3 * z_4 - 0.10479 * z_3 * z_5 + 0.18713 \\
&* z_3 * z_6 - 0.086236 * z_4 * z_6 - 0.056937 * z_5 * z_6 \\
&+ 0.066719 * z_6 * z_7 - 0.087469 * z_2^2 + 0.075313 * z_4^2 \\
&+ 0.04108 * z_5^2 - 0.12736 * z_6^2
\end{aligned}$$

Las estadísticas de la bondad de ajuste del modelo son:

$$RMSE_{b-c} = 0.261, r_{b-c}^2 = 0.8, r^2 adj_{b-c} = 0.753, F_{b-c} = 17.2; valor - p = 3.86e - 28$$

El ajuste del modelo a los datos experimentales es muy bueno. De las predicciones obtenidas con la ecuación(3-12), se debe obtener la transformada inversa Box-Cox, que se realiza según la siguiente ecuación:

(3-13)

$$\mathbf{Retenido}_{inv} = (\mathbf{Retenido} * \lambda_f + 1)^{\frac{1}{\lambda_f}}$$

con $\lambda_f = 1.1129$. Los valores de **Retenido**_{inv} son comparadas con los datos experimentales del retenido de malla No. 325 para el estudio de los residuos.

En la Figura 3-25 se muestra la gráfica de probabilidad normal y la gráfica del residuo tipificado de este modelo.

El *valor-p* de la prueba de Anderson-Darling es de 0.0036. Con un nivel de significancia del 1%, el test sugiere que la distribución del residuo no es normal. Los gráficos de normalidad del error, muestran que éste sigue una distribución aproximadamente normal. El estadístico Durbin-Watson es 2.147, lo que indica que el error no está auto-correlacionado.

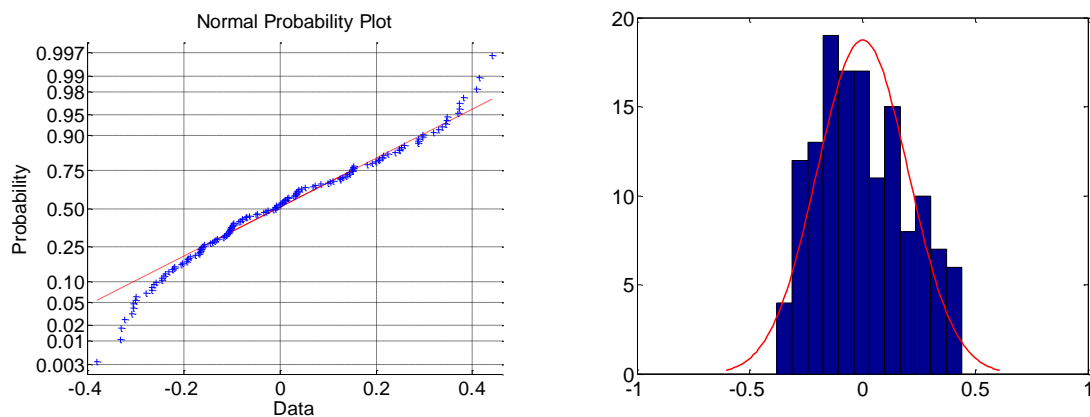


Figura 3-25. Gráfico de probabilidad normal y residuos tipificados de modelo del retenido de malla No. 325 con transformación Box-Cox

En la Figura 3-26 se observa el ajuste obtenido del modelo a los datos experimentales y el intervalo de confianza del 95%.




Figura 3-26. Ajuste del modelo con transformación Box-Cox de la fineza de retenido de malla 325

El modelo es muy bueno; los valores de las predicciones son muy aproximados a los experimentales.

El estadístico PRESS obtenido para este modelo es:

$$PRESS_{b-c} = 8.5944; R^2_{predic_{b-c}} = 0.7739$$

La capacidad de predicción del modelo es alta.

3.6.2.2.4 Selección del mejor modelo estadístico para el retenido de malla No. 325

Los modelos que serán considerados en la validación con un nuevo set de datos son el modelo largo de segundo orden y el modelo con transformación Box-Cox.

El modelo con transformación Box-Cox promete mejores resultados en la predicción de nuevos datos.

En la Figura 3-27 se muestra el comportamiento los modelos en la predicción de los datos experimentales.

El modelo largo de segundo orden y el modelo con transformación Box-Cox tienen un ajuste similar.




Figura 3-27. Comparación de los modelos estadísticos del retenido de malla No. 325



3.7 Modelos dinámicos

En esta sección se presentan los modelos dinámicos del Blaine y del retenido de malla No. 325. Los modelos desarrollados son los autorregresivos.

Los modelos autorregresivos se basan en los modelos de regresión lineal múltiple presentada en la sección de modelación estadística, pero en este caso además de las variables de proceso seleccionadas se incluyen también, como variables explicativas, los valores pasados (retrasos) de la variable de calidad modelada.

Según se determinó en la modelación estadística, los modelos de regresión lineal múltiple que incluyen variables de segundo orden y combinación de las variables independientes proporcionan los mejores resultados (similares a los modelos con transformación Box-Cox de la variable dependiente) en el ajuste a los valores experimentales. De acuerdo a esto, se plantea encontrar un modelo autorregresivo tomando como modelo base, de entrada al método del *stepwise*, un modelo largo de segundo orden en donde además se incluyan como variables de regresión básicas, los retrasos de la variable de calidad modelada.

Para obtener el número de retrasos de la variable de calidad, que se incluirán en el modelo base, se realiza el correlograma, donde los retrasos considerados serán aquellos que estén fuera del intervalo de confianza del 95%.

El procedimiento de la modelación autorregresiva es la misma que para la modelación estadística; es decir al determinar la ecuación del modelo se procede analizar su bondad de ajuste, estudiar los residuos y establecer el intervalo de confianza.

3.7.1 Modelos autorregresivos de las variables de calidad

Los modelos autorregresivos que se presentan son modelos largos de segundo orden, con inclusión de los retrasos de la variable de calidad en el conjunto de variables explicativas. Al igual que en la modelación estadística las variables de proceso seleccionadas para el modelamiento se estandarizan.

3.7.1.1 Modelo autorregresivo del Blaine

En este modelo se plantea incluir como variable explicativa, además de las variables de regresión en segundo orden, un retraso de la variable de calidad Blaine como sugiere el análisis del correlograma (Figura 3-28).




Figura 3-28. Correlograma del Blaine

En la Figura 3-28 se observa que el desfase uno de la variable Blaine puede ser usado como variable de regresión en el modelo autorregresivo.

De esta forma el modelo base es:

$$\begin{aligned}
 \text{Blaine}_{\text{mbautrr}} = & 1 + z_1 + z_2 + z_3 + z_4 + z_5 + z_6 + z_7 + y_{k1} + z_1 * z_2 + z_1 * z_3 \\
 & + z_1 * z_4 + z_1 * z_5 + z_1 * z_6 + z_1 * z_7 + z_1 * y_{k1} + z_2 * z_3 \\
 & + z_2 * z_4 + z_2 * z_5 + z_2 * z_6 + z_2 * z_7 + z_2 * y_{k1} + z_3 * z_4 + z_3 \\
 & * z_5 + z_3 * z_6 + z_3 * z_7 + z_3 * y_{k1} + z_4 * z_5 + z_4 * z_6 + z_4 * z_7 \\
 & + z_4 * y_{k1} + z_5 * z_6 + z_5 * z_7 + z_5 * y_{k1} + z_6 * z_7 + z_6 * y_{k1} \\
 & + z_7 * y_{k1} + z_1^2 + z_2^2 + z_3^2 + z_4^2 + z_5^2 + z_6^2 + z_7^2 + y_{k1}^2
 \end{aligned}
 \tag{3-14}$$

donde, y_{k1} representa el retraso de la variable de calidad Blaine y , de una muestra. Las variables z son de proceso, seleccionadas para el modelo del Blaine identificadas en la Tabla 3-10.

Con el mismo procedimiento implementado en la modelación estadística se determina el modelo autorregresivo:

(3-15)

$$\begin{aligned} \text{Blaine}_{\text{mautorr}} = & 4246.8 + 11.964 * z1 * z2 + 14.328 * z1 * z4 \\ & + 13.123 * z1 * z5 - 0.067483 * z1 * yk1 - 10.129 * z2 * z4 - \\ & 12.971 * z3 * z5 + 37.158 * z3 * z6 + 0.07286 * z3 * yk1 + \\ & 16.075 * z4 * z7 + 15.141 * z5 * z7 - 9.7609 * z1^2 + 27.385 * \\ & z2^2 - 33.555 * z5^2 - 8.6811 * z6^2 \end{aligned}$$

127

Las estadísticas de la bondad de ajuste del modelo son:

$$RMSE_{\text{mautorr}} = 67.4, \quad r^2_{\text{mautorr}} = 0.597, \quad r^2_{adj_{\text{mautorr}}} = 0.541, \quad F_{\text{mautorr}} = 10.7; \text{valor} - p = 1.38e - 21$$

El ajuste del modelo es bueno.

En la Figura 3-29 se muestra la gráfica de probabilidad normal y la gráfica del residuo tipificado del modelo autorregresivo.

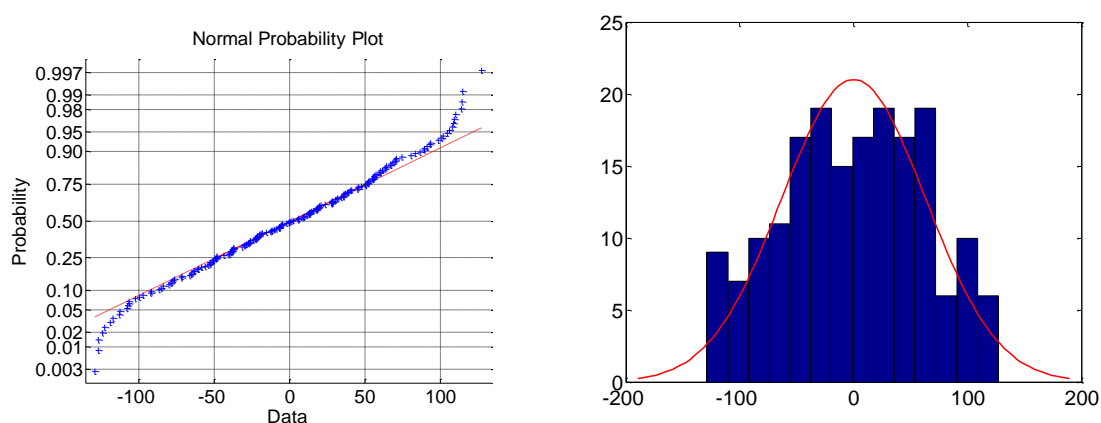


Figura 3-29. Gráfico de probabilidad normal y residuos tipificados del modelo autorregresivo del Blaine

El valor-p de la prueba de Anderson-Darling es de 0.1283. Con un nivel de significancia del 1%, el test sugiere que la distribución del residuo es normal. Los gráficos de normalidad del error, demuestran que éste sigue una distribución normal.

El estadístico Durbin-Watson es 2.142, lo que indica que el error no está autocorrelacionado.

En la Figura 3-30 se observa el ajuste obtenido del modelo a los datos experimentales y el intervalo de confianza del 95%.




Figura 3-30. Ajuste del modelo autorregresivo del Blaine

Se observa que los valores de las predicciones son muy aproximados a los datos experimentales.

El estadístico PRESS obtenido para este modelo es:

$$PRESS_{\text{mautorr}} = 9.3359e + 05; R^2_{\text{predic}_{\text{mautorr}}} = 0.4787$$

La capacidad de predicción del modelo no es buena.

3.7.1.2 Modelo autorregresivo del retenido de malla No. 325

En este modelo se incluye como variable explicativa, además de las variables de regresión en segundo orden, un retraso de la variable de calidad de fineza, del retenido de malla No. 325, de acuerdo al análisis del correlograma mostrado en la Figura 3-31.

129




Figura 3-31. Correlograma del retenido de mall No. 325

Según el correlograma para el retenido, esta variable de calidad se correlaciona significativamente con su desfase en una unidad de tiempo. Por tanto el primer este retraso se utilizará en la modelación autorregresiva.

El modelo base, considerando un desfase de la variable de calidad es:

(3-16)

Retenido_{mbautrr}

$$\begin{aligned}
 &= 1 + z1 + z2 + z3 + z4 + z5 + z6 + z7 + yk1 + z1 * z2 + z1 \\
 &* z3 + z1 * z4 + z1 * z5 + z1 * z6 + z1 * z7 + z1 * yk1 + z2 \\
 &* z3 + z2 * z4 + z2 * z5 + z2 * z6 + z2 * z7 + z2 * yk1 + z3 * z4 \\
 &+ z3 * z5 + z3 * z6 + z3 * z7 + z3 * yk1 + z4 * z5 + z4 * z6 \\
 &+ z4 * z7 + z4 * yk1 + z5 * z6 + z5 * z7 + z5 * yk1 + z6 * z7 + z6 \\
 &* yk1 + z7 * yk1 + z1^2 + z2^2 + z3^2 + z4^2 + z5^2 + z6^2 + z7^2 \\
 &+ yk1^2
 \end{aligned}$$

donde y_{k1} representa el desfase la variable de calidad fineza de retenido de malla No. 325 y, de una muestra. Las variables z son de proceso, seleccionadas para el modelo de la fineza de retenido de malla No. 325 identificadas en la Tabla 3-10.

Siguiendo el mismo procedimiento de la modelación estadística se determina el modelo autorregresivo:

$$\begin{aligned}
 \text{Retenido}_{\text{mautorr}} &= 3.5813 + 0.16833 * z_1 * z_2 + 0.078116 * z_1 * z_3 + 0.093198 \\
 &* z_1 * z_5 + 0.10236 * z_1 * z_6 - 0.057918 * z_2 * z_3 - 0.22706 \\
 &* z_2 * z_4 + 0.10483 * z_2 * z_5 + 0.090427 * z_2 * z_6 - 0.20871 \\
 &* z_2 * z_7 + 0.074573 * z_2 * y_{k1} + 0.1214 * z_3 * z_4 - 0.10367 \\
 &* z_3 * z_5 + 0.11849 * z_3 * z_6 + 0.041318 * z_3 * z_7 - 0.064909 \\
 &* z_4 * z_6 + 0.053422 * z_4 * z_7 - 0.065377 * z_5 * z_6 - 0.076066 \\
 &* z_5 * y_{k1} + 0.044943 * z_6 * z_7 - 0.084939 * z_2^2 + 0.087574 \\
 &* z_4^2 + 0.045145 * z_5^2 - 0.10494 * z_6^2
 \end{aligned}
 \tag{3-17}$$

Las estadísticas de la bondad de ajuste del modelo son:

$$RMSE_{\text{mautorr}} = 0.239, \quad r^2_{\text{mautorr}} = 0.792, \quad r^2_{adj_{\text{mautorr}}} = 0.735, \quad F_{\text{mautorr}} = 14; \text{valor} - p = 2.87e - 26$$

El modelo se ajusta muy bien a los datos experimentales.

En la Figura 3-32 se muestra la gráfica de probabilidad normal y la gráfica del residuo tipificado del modelo autorregresivo.

El valor-p de la prueba de Anderson-Darling es de 0.0253. Con un nivel de significancia del 1%, el test sugiere que la distribución del residuo es normal. Los gráficos de normalidad del error, demuestran que éste sigue una distribución normal.




Figura 3-32. Gráfico de probabilidad normal y residuos tipificados del modelo autorregresivo del retenido de malla No. 325

En la Figura 3-33 se observa el ajuste obtenido del modelo a los datos experimentales y el intervalo de confianza del 95%.




Figura 3-33. Ajuste del modelo autorregresivo del retenido de malla No. 325

Los resultados obtenidos del modelo son muy aproximados a los datos experimentales.

El estadístico PRESS obtenido para este modelo es:

$$PRESS_{\text{mautorr}} = 10.6000; R^2_{\text{predic}_{\text{mautorr}}} = 0.6599$$

La capacidad de predicción del modelo es buena.

3.8 Modelos Neuronales

En esta sección se presentan los modelos neuronales del Blaine y de la fineza de retenido de malla No. 325.

3.8.1 Modelos neuronales de las variables de calidad

Los modelos neuronales que se presentan son modelos con entradas de 7 variables de operación (Tabla 3-10) y la salida corresponde a la variable de calidad.

Los modelos de redes neuronales fueron creados con los valores por defecto de la herramienta *nntool* de *MATLAB*. Los parámetros de la red utilizados fueron los mismos para todas las funciones de entrenamiento como se estudió en la sección de modelación neuronal. En primera instancia se utilizaron 2 capas ocultas, la primera con 10 neuronas y la segunda con una sola neurona debido a que se trata de una salida. Las funciones de transferencia son de tipo tansigmoidales.

El procedimiento que se muestra a continuación se lo realiza para las dos variables de calidad primero para el Blaine y después para el retenido de malla.

3.8.1.1 Proceso de entrenamiento para la creación de la red neuronal

El proceso de entrenamiento para la estimación de los modelos de Blaine y fineza de retenido de malla mediante la creación de redes neuronales se realiza de acuerdo al siguiente procedimiento:

1. Crear la red neuronal con los valores de Blaine y retenido de malla correspondientes a la planta de cemento. Los valores de entrada son las variables de operación (Tabla 3-10) mientras que los valores deseados corresponden a las variables de calidad. La Figura 3-34 muestra la herramienta *nntool* de *MATLAB* y su estructura de creación de la red neuronal.

133

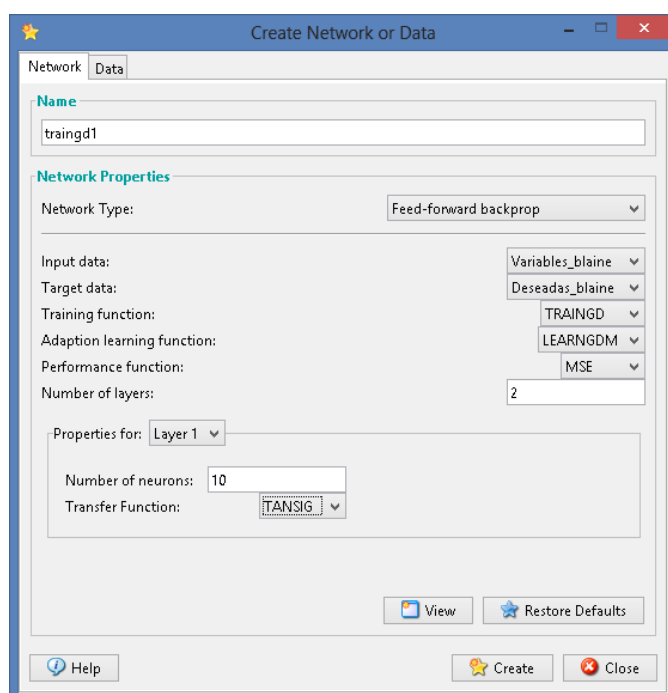


Figura 3-34. Creación de una red neuronal

2. Entrenar la red con cada una de las funciones de entrenamiento descritas anteriormente: `trainbfg`, `traincgb`, `traincgp`, `traingd`, `traingda`, `traingdm`, `traingdx`, `trainlm` y `trainrp`.
3. Determinar los valores de media y desviación estándar del error, y del parámetro de ajuste R de cada modelo propuesto para cada función de entrenamiento. Escoger el modelo con mejores resultados.
4. Entrenar la red con diferente número de neuronas en la capa oculta: 5, 10, 15, 20, 25, 30, 35, 40, 45 y 50.

5. Determinar los valores de media y desviación estándar del error, y del parámetro de ajuste R de cada modelo propuesto para cada función de entrenamiento. Escoger el modelo con mejores resultados.
6. Entrenar la red con la combinación de las funciones de activación para la primera y segunda capas ocultas: logsigmoidal-purelin, logsigmoidal-logsigmoidal, logsigmoidal-tansigmoidal, tansigmoidal-purelin, tansigmoidal-tansigmoidal, tansigmoidal-logsigmoidal, purelin-purelin, purelin-tansigmoidal y purelin-logsigmoidal.
7. Determinar los valores de media y desviación estándar del error, y del parámetro de ajuste R de cada modelo propuesto para cada función de entrenamiento. Escoger el modelo con mejores resultados.
8. Seleccionar los pesos y umbrales determinados con el mejor resultado de entrenamiento.

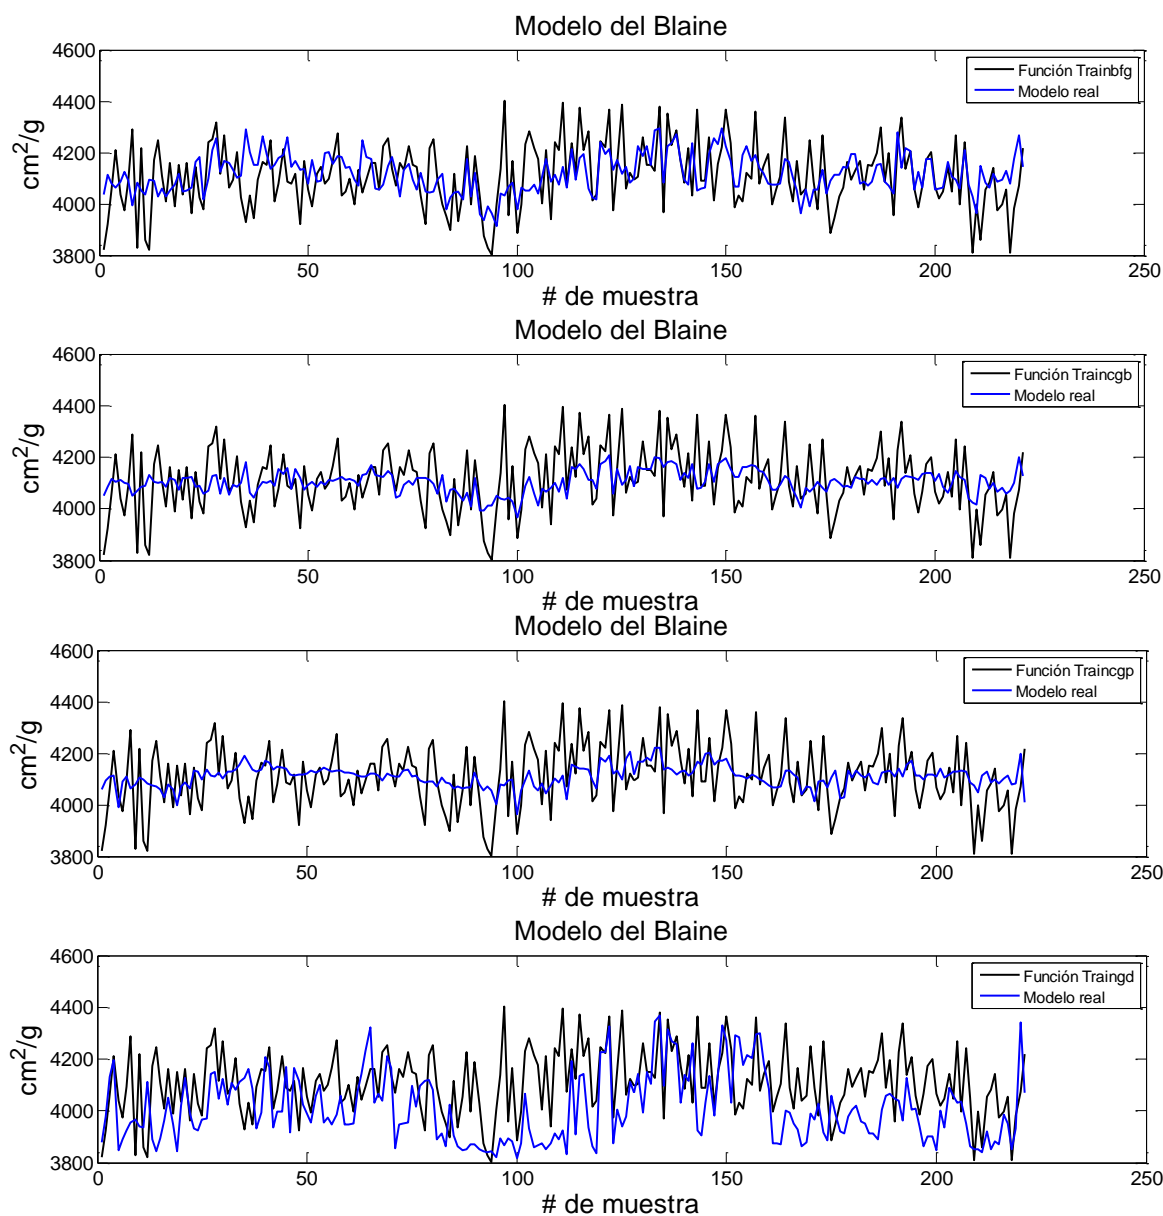
3.8.1.2 Modelo neuronal del Blaine

La Tabla 3-11 muestra el análisis de los valores correspondientes al número de iteraciones, coeficiente de regresión lineal R , media y desviación estándar del error.

Tabla 3-11. Análisis estadístico de las funciones de entrenamiento

Funciones de Entrenamiento	Número de Iteraciones	R	Media	Desviación estándar
Trainbfg	12	0.35945	-7.672	121.4516
Traincgb	15	0.36717	4.5972	117.6803
Traincgp	17	0.31542	-1.6916	120.0286
Traingd	2	0.30459	98.5816	151.9882
Traingda	59	0.28696	13.0983	124.0747
Traingdm	2	0.18298	58.0928	157.5056
Traingdx	33	0.18874	-19.4304	154.1619
Trainlm	11	0.59129	5.6634	102.8161
Trainrp	17	0.29496	-10.6443	123.9838

La Figura 3-35 presenta los resultados de los modelos estimados por cada una de las funciones de entrenamiento mencionadas anteriormente.



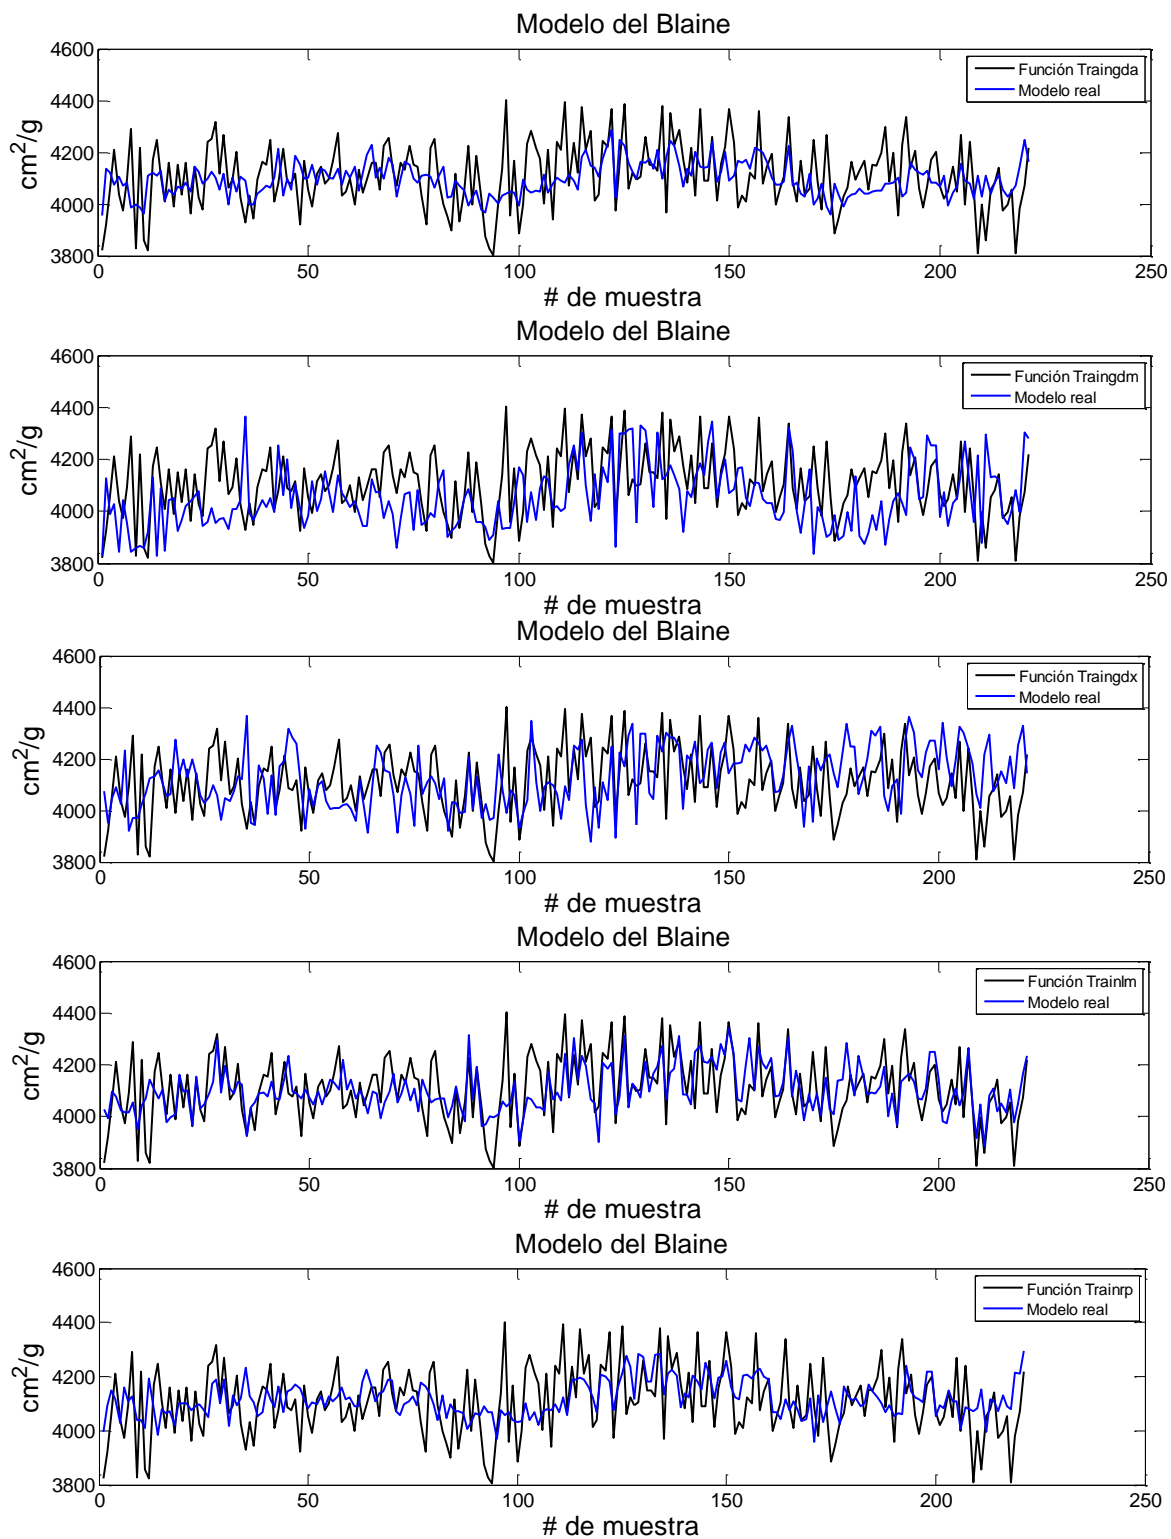


Figura 3-35. Modelos de predicción para el Blaine para las funciones de entrenamiento

Para la elección del modelo más satisfactorio se usan los histogramas del error de cada una de las funciones. Lo que se busca en un histograma es que el error se encuentre centrado en el valor igual a cero y que los valores sean simétricos en relación al mismo valor. Los histogramas del error de las funciones de entrenamiento se muestran en la Figura 3-36.

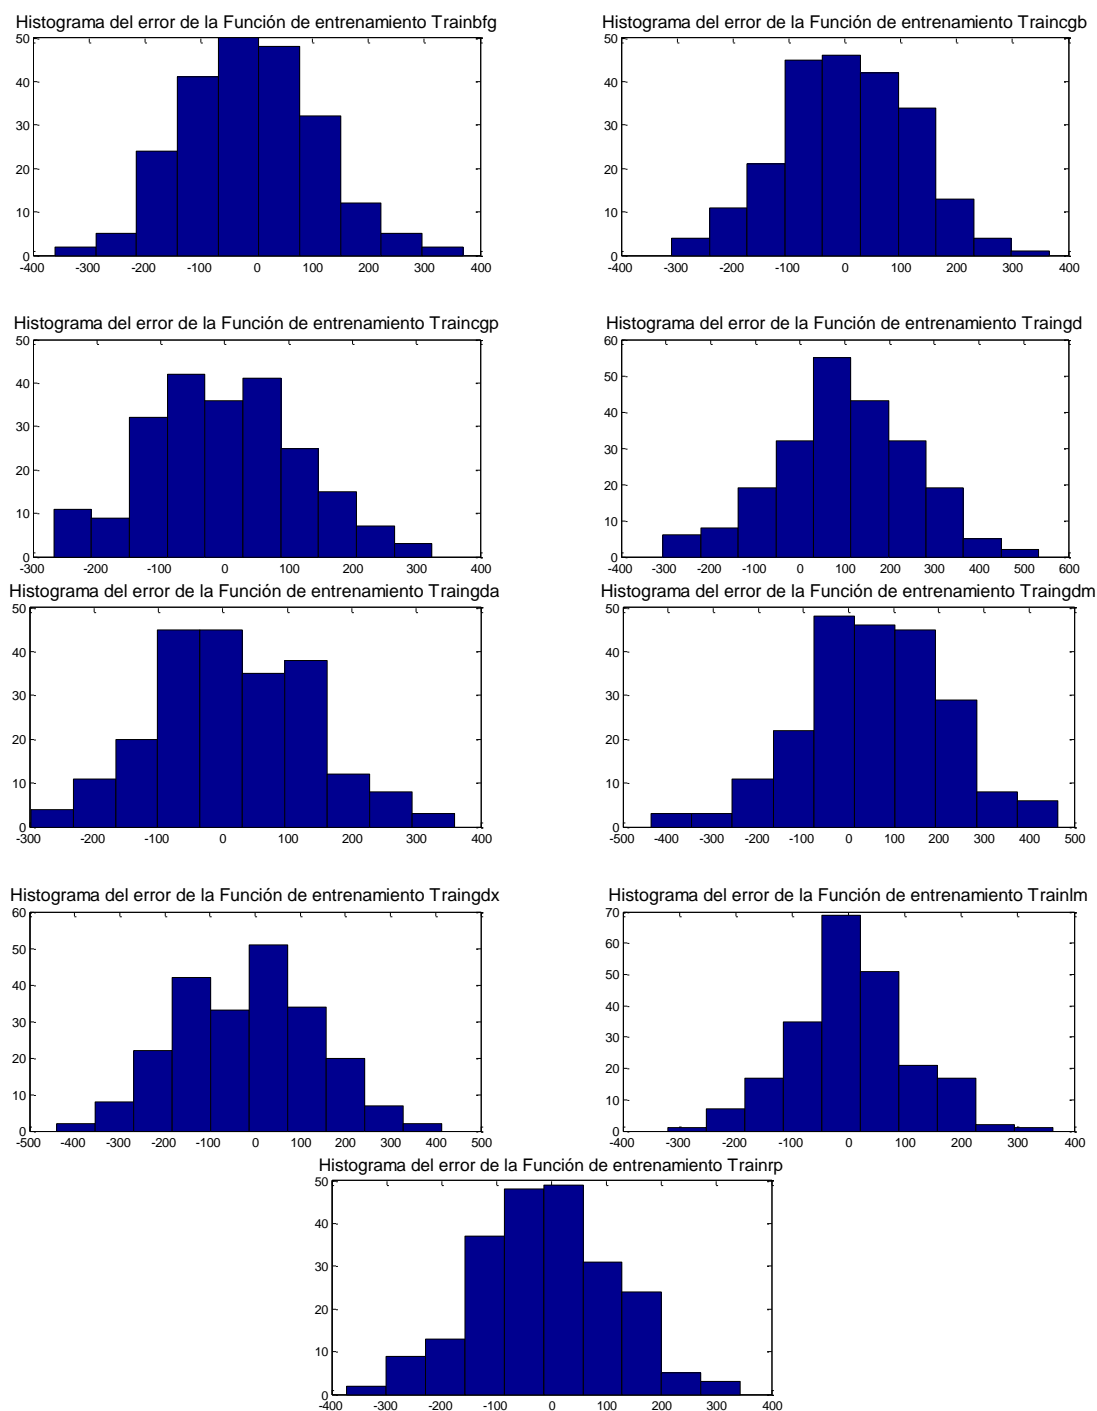


Figura 3-36. Histogramas del error de predicción para las funciones de entrenamiento

Los resultados obtenidos son: en la Tabla 3-11 se observa que el modelo con mejor coeficiente de regresión lineal R y desviación estándar es la función de entrenamiento de Levenberg-Marquardt Trainlm. La función de entrenamiento que presenta mejor media del error es Traincgp. El histograma del error con mejor desempeño es el de la función Trainrp.

La función de entrenamiento elegida es Trainlm. Trainlm presenta el mejor R , una media y variación estándar bajos y una aceptable distribución del error que se observa en su histograma correspondiente. La estimación del modelo se observa en la Figura 3-35. La autorregresión lineal correspondientes a las fases de entrenamiento, validación y comprobación de la función de entrenamiento escogida se observan en la Figura 3-37.

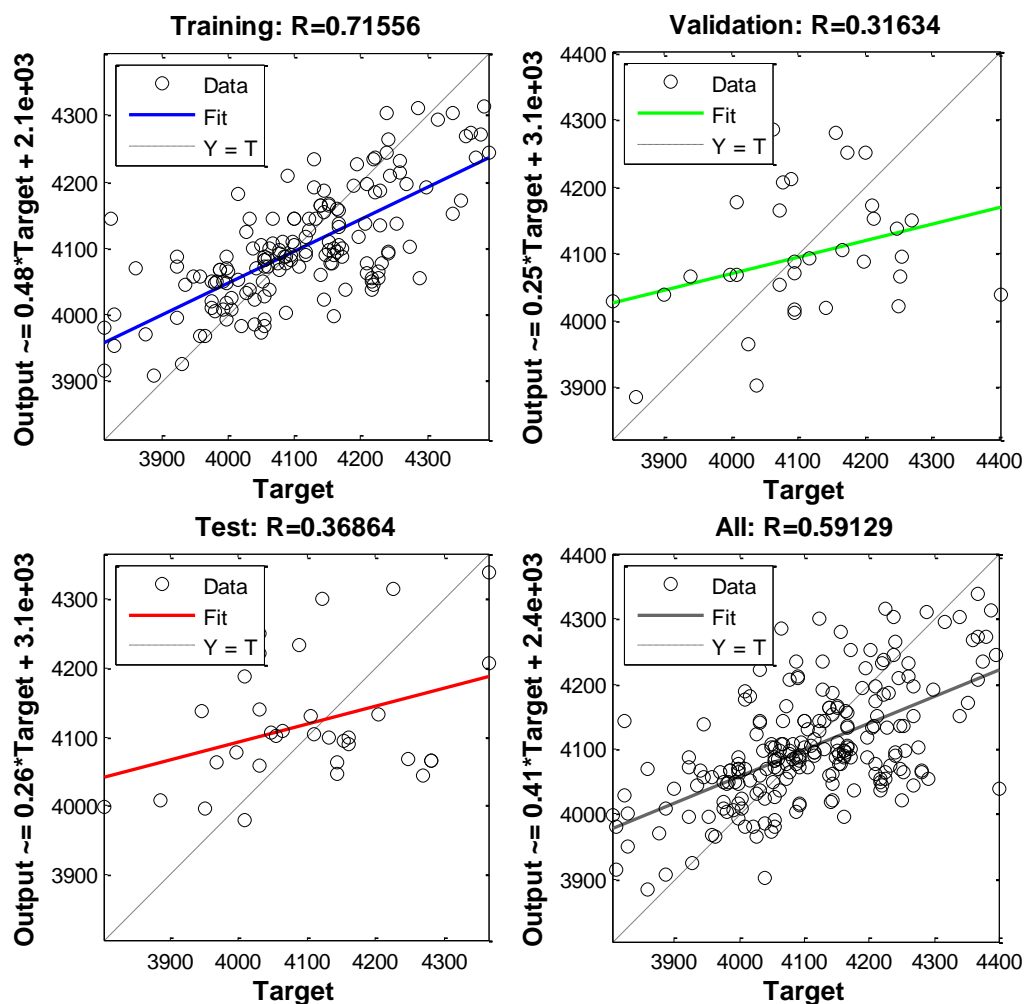


Figura 3-37. Autorregresión lineal de la función de entrenamiento Trainlm

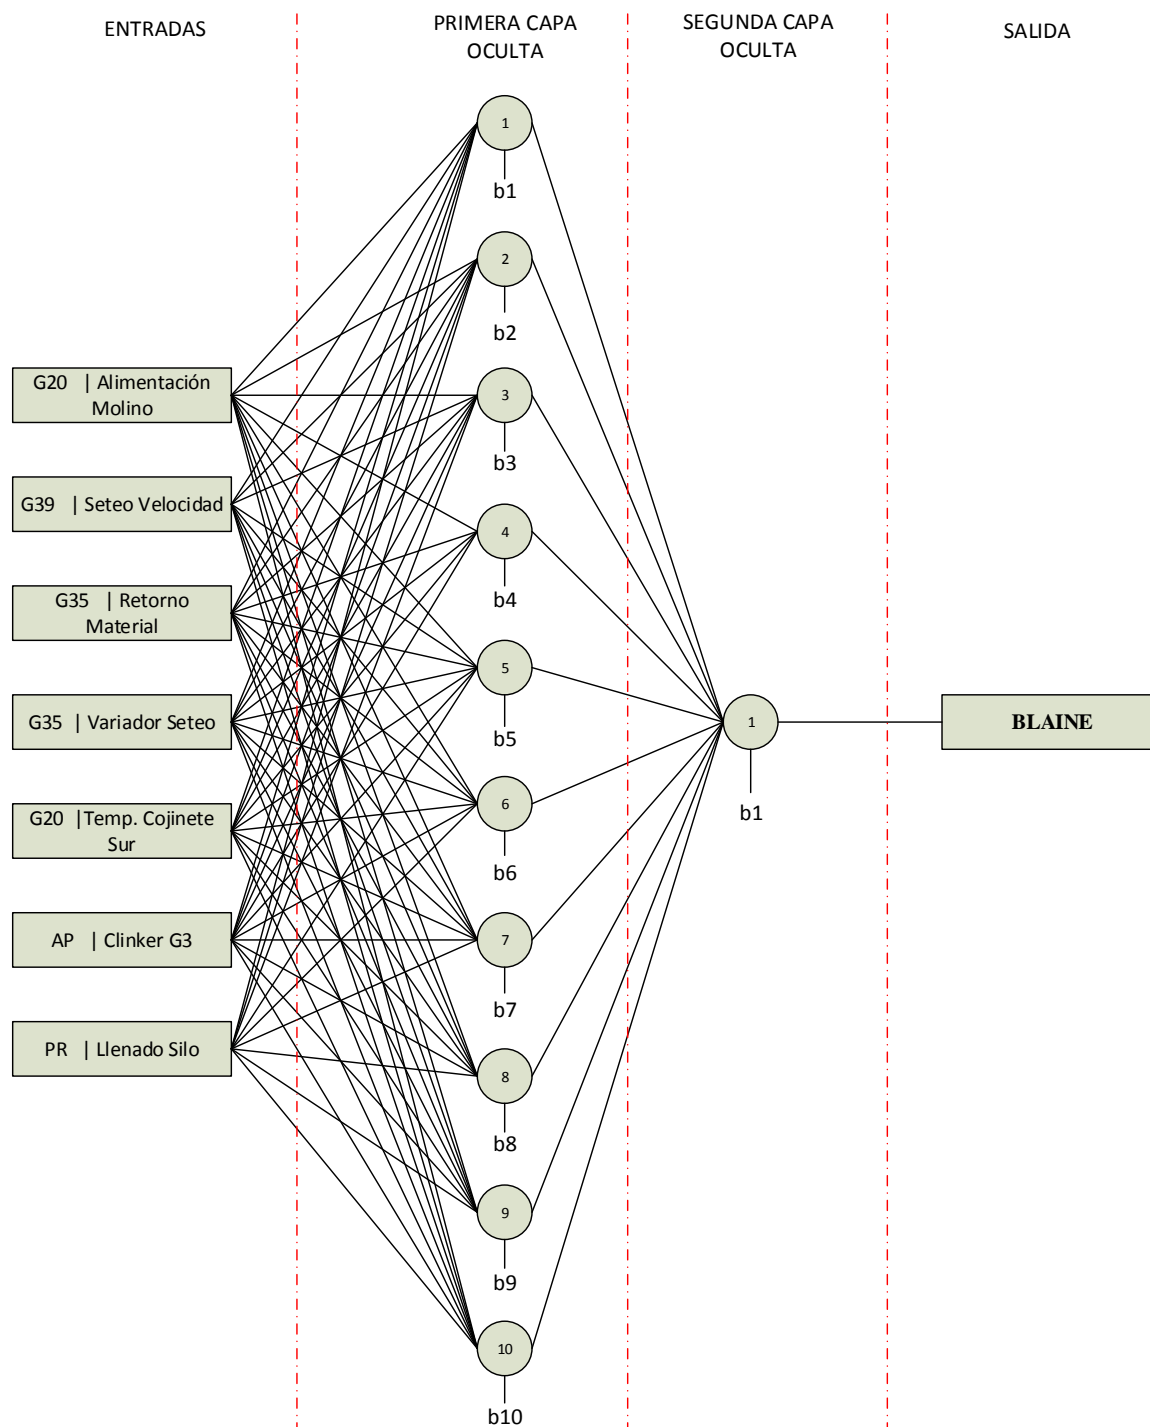


Figura 3-38. Red Neuronal para el modelo de predicción para el Blaine

La Figura 3-38 muestra la estructura general de la red neuronal. La función de entrenamiento permite encontrar los valores óptimos para los pesos y umbrales de la red. Los pesos corresponden a las conexiones entre cada una de las entradas y las neuronas de la capa oculta. La primera capa oculta cuenta con 70 pesos debido a sus 7 entradas y 10 neuronas de la capa oculta. La segunda capa oculta cuenta con 10 pesos debido a que existe una sola salida de la red. Cada neurona tiene asociado un umbral, por lo que hay 10 umbrales en la primera capa oculta y 1 umbral en la segunda capa oculta.

El número de neuronas en las capas ocultas se han trabajado con los valores por defecto que determina la herramienta de *MATLAB*. Mediante el proceso de prueba y error se determina el número de neuronas adecuado para la red. El análisis se lo realiza mediante la comparación de *R*.

La Tabla 3-12 muestra las estimaciones de los modelos de las redes neuronales realizados con diferentes números de neuronas. Las pruebas se realizaron tres veces debido a que los pesos y umbrales se inician de forma aleatoria. Se realiza un promedio de los tres procesos para obtener el mejor estimado.

Tabla 3-12. Análisis de número de neuronas del modelo

#Neuronas	R			R promedio
	1	2	3	
5	0.26989	0.16334	0.38361	0.27228
10	0.44772	0.40005	0.51815	0.45530667
15	0.49379	0.47649	0.44594	0.47207333
20	0.42898	0.44956	0.42717	0.43523667
25	0.61765	0.5042	0.52461	0.54882
30	0.564	0.58539	0.5037	0.55103
35	0.3192	0.63757	0.58297	0.51324667
40	0.54745	0.52249	0.44781	0.50591667
45	0.66198	0.57307	0.65876	0.63127
50	0.55644	0.36683	0.47812	0.46713

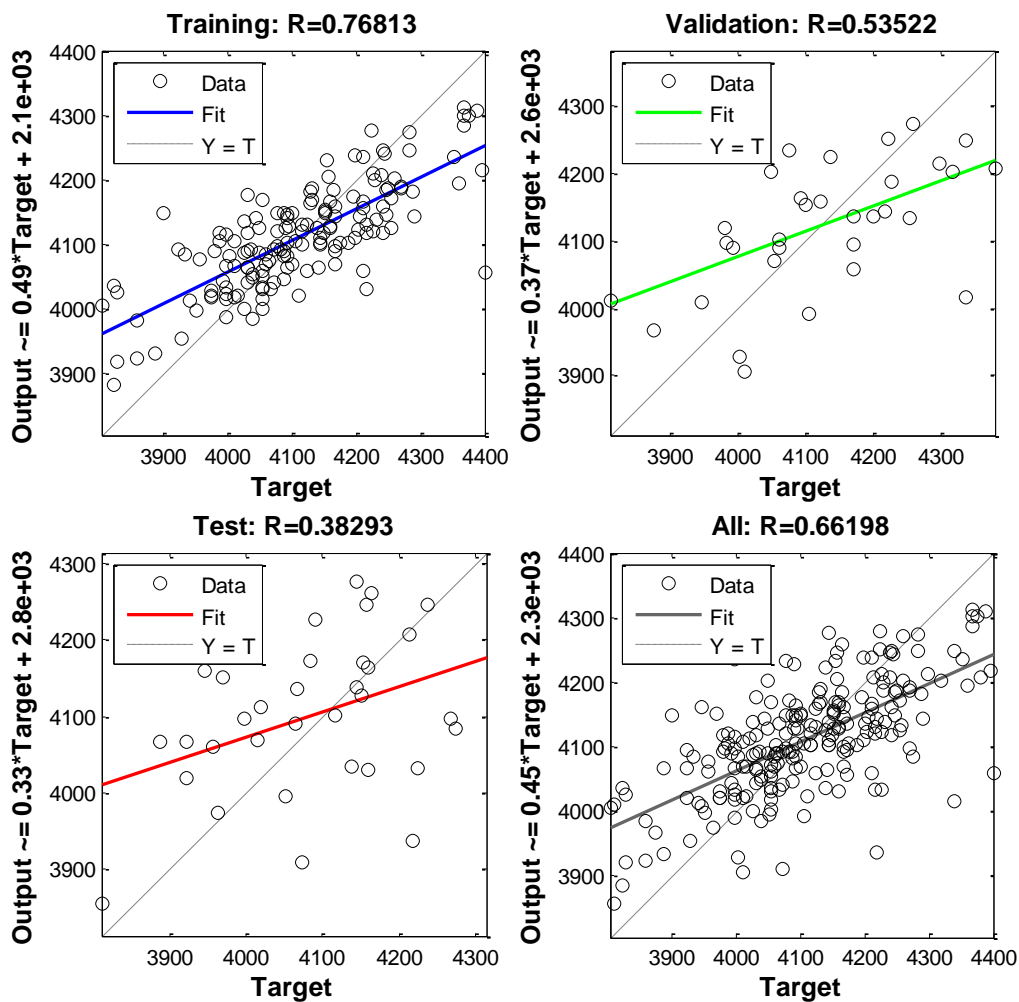


Figura 3-39. Autorregresión lineal del modelo de predicción con 40 neuronas




Figura 3-40. Modelo de predicción para el Blaine con 40 neuronas

El modelo estimado con 45 neuronas en la primera capa oculta muestra una R promedio mejor que las demás estimaciones. El modelo escogido es el que posee el valor máximo de R de 0.66198. La Figura 3-39 presenta la autorregresión lineal del modelo y Figura 3-40 la estimación del modelo en comparación con los datos reales de la planta.

La función de entrenamiento y el número de neuronas en la capa oculta ya han sido establecidas, pero no así la función de transferencia de las neuronas. La función utilizada es tansigmoidal que el toolbox de *MATLAB* asigna por defecto.

MATLAB incorpora tres funciones de transferencia: tansigmoidal, logsigmoidal y purelin. Para determinar la mejor combinación se realiza una comparación entre las diferentes funciones de activación para las capas ocultas. El análisis de las funciones de transferencia se muestra en la Tabla 3-13 con su respectivo coeficiente de autorregresión lineal R . Las pruebas realizadas se repitieron tres veces debido a que los pesos se inicializan de forma aleatoria. Se realiza un promedio de las tres pruebas realizadas y la combinación que mejor resultado genere será el escogido.

Tabla 3-13. Análisis de las funciones de transferencia del modelo

#	Capa Oculta 1	Capa Oculta 2	R			Rpromedio
			R1	R2	R3	
1	tansig	tansig	0,69517	0,58839	0,62594	0,6365
2	tansig	logsig	0,37382	0,37078	0,36574	0,37011333
3	tansig	purelin	0,50097	0,57947	0,427	0,50248
4	logsig	tansig	0,56174	0,44519	0,52525	0,51072667
5	logsig	logsig	0,34921	0,3708	0,36608	0,36203
6	logsig	purelin	0,44538	0,43574	0,44195	0,44102333
7	purelin	tansig	0,43056	0,38214	0,5902	0,46763333
8	purelin	logsig	0,3132	0,30166	0,32242	0,31242667
9	purelin	purelin	0,43672	0,51138	0,26143	0,40317667

Los resultados obtenidos en la Tabla 3-13 entregan como mejor estimación la combinación de las funciones de activación tansigmoidal-tansigmoidal. La estimación contiene el máximo absoluto de las estimaciones con $R=0.69517$.



Una vez realizado el análisis completo para la creación de la red neuronal, el modelo de estimación resulta: una red con 2 capas ocultas, 45 neuronas en la primera capa oculta, 1 neurona en la segunda capa oculta (1 sola salida), función de entrenamiento Trainlm, función de activación tansigmoidal para las dos capas ocultas y con una estimación R total de 0.69517 equivalente al 69.517% de certeza del modelo.

La autorregresión lineal R para las fases de entrenamiento, validación y comprobación se muestran en la Figura 3-41. La estimación del modelo propuesto en comparación del modelo real del sistema se observa en la Figura 3-42.

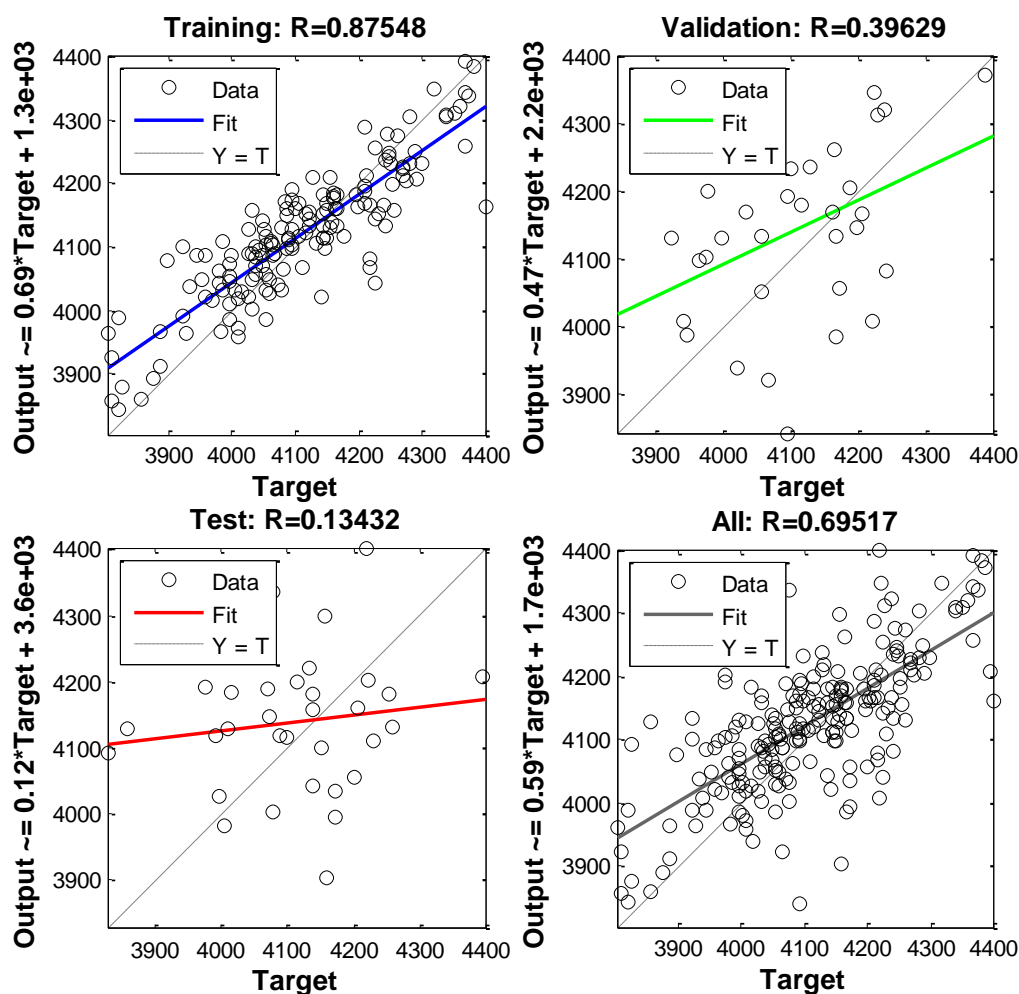


Figura 3-41. Autorregresión lineal del modelo con función de transferencia tansigmoidal




Figura 3-42. Modelo de predicción con la función de transferencia tansigmoidal

El modelo final para la estimación del Blaine está determinado por la siguiente ecuación:

$$\text{Modelo neuronal}_{\text{Blaine}} = f\{W2 * [f(w1 * X + b1)] + b2\} \quad (3-18)$$

Donde $W1, W2, b1$ y $b2$ son las matrices correspondientes a los pesos y umbrales mencionados anteriormente, f es la función de activación tansigmoidal. X es el vector de entradas dado por:

$$X = \begin{bmatrix} X1: G20 | Alimentación Molino \\ X2: G39 | Seteo Velocidad \\ X3: G35 | Retorno Material \\ X4: G35 | Variador Seteo \\ X5: G20 | Temp. Cojinete Sur \\ X6: AP | Clinker G3 \\ X7: PR | Llenado Silo \end{bmatrix}$$

3.8.1.3 Modelo neuronal de la fineza de malla No. 325

El proceso para la obtención del modelo neuronal para la fineza de malla No. 325 será el estudiado en el capítulo 2 en el procedimiento para la modelación neuronal.




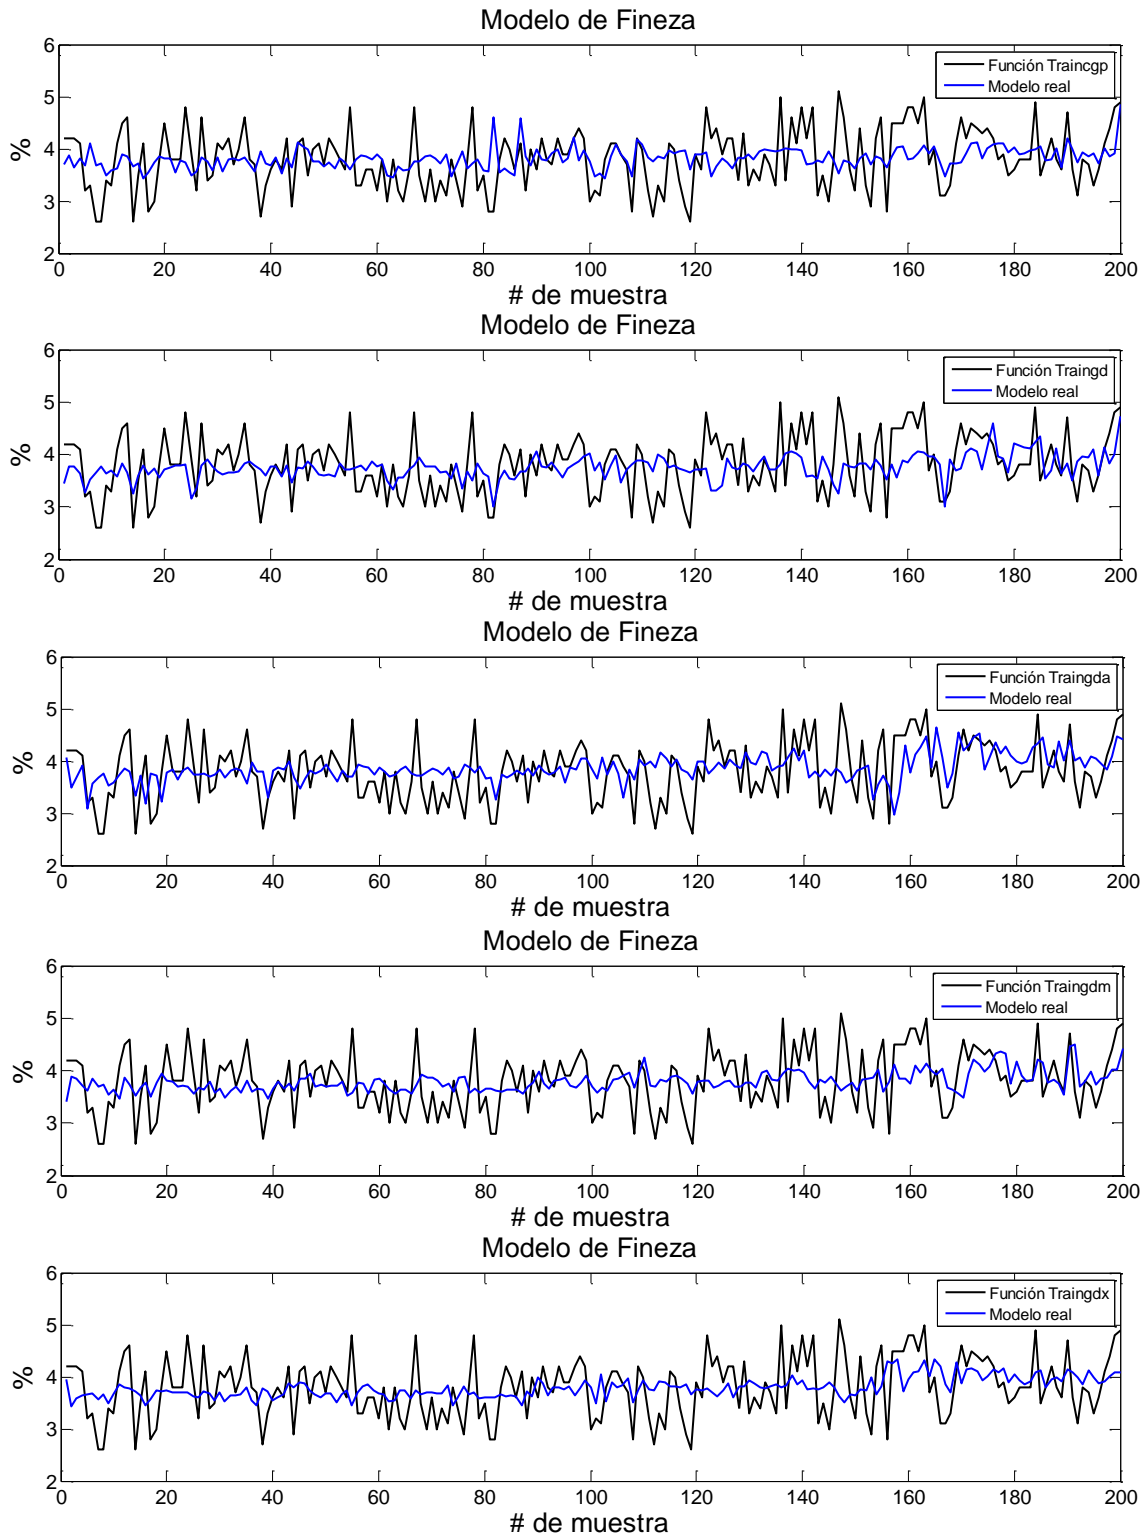
La Tabla 3-14 presenta el análisis del coeficiente de autorregresión lineal, número de iteraciones, media y desviación estándar del error.

Tabla 3-14. Análisis estadístico de las funciones de entrenamiento

Funciones de Entrenamiento	# Iteraciones	R	Media	Desviación estándar
Trainbfg	6	0.30043	-0.0123	0.5515
Traincgb	16	0.3224	-0.0432	0.5475
Traincgp	19	0.23843	-0.014	0.5651
Traingd	618	0.25235	0.0477	0.5655
Traingda	919	0.27137	-0.056	0.5647
Traingdm	93	0.2769	0.0112	0.5575
Traingdx	87	0.21066	0.0096	0.5695
Trainlm	12	0.47471	-0.0698	0.5091
Trainrp	36	0.4593	0.243	0.5144

Las estimaciones de los modelos de predicción frente a los valores reales de la planta para cada función de entrenamiento se observa en la Figura 3-43.









Figura 3-43. Modelos de predicción para la fineza de malla No. 325 para las funciones de entrenamiento

Además la Figura 3-44 presenta los histogramas del error de los modelos de predicción para cada una de las funciones de entrenamiento mencionadas.


Trainlm presenta la mejor autorregresión lineal R y desviación estándar. Traingdx posee la media más cercana a cero. No es posible escoger una función de entrenamiento mejor en cuanto a los histogramas del error. La función de entrenamiento elegida es Trainlm. Esta función de entrenamiento presenta una estimación del modelo correspondiente a 0.47471, una media y distribución del error aceptables y la mejor desviación estándar.

La Figura 3-45 presenta la autorregresión lineal para las fases de entrenamiento, validación y comprobación del modelo escogido.


Histograma del error de la Función de entrenamiento Trainbfg




Histograma del error de la Función de entrenamiento Traincgb




Histograma del error de la Función de entrenamiento Traincgp




Histograma del error de la Función de entrenamiento Traincgd




Histograma del error de la Función de entrenamiento Traingda




Histograma del error de la Función de entrenamiento Traingdm



Histograma del error de la Función de entrenamiento Traingdx



Histograma del error de la Función de entrenamiento Trainlm



Histograma del error de la Función de entrenamiento Trainrp




Figura 3-44. Histogramas del error de predicción para las funciones de entrenamiento

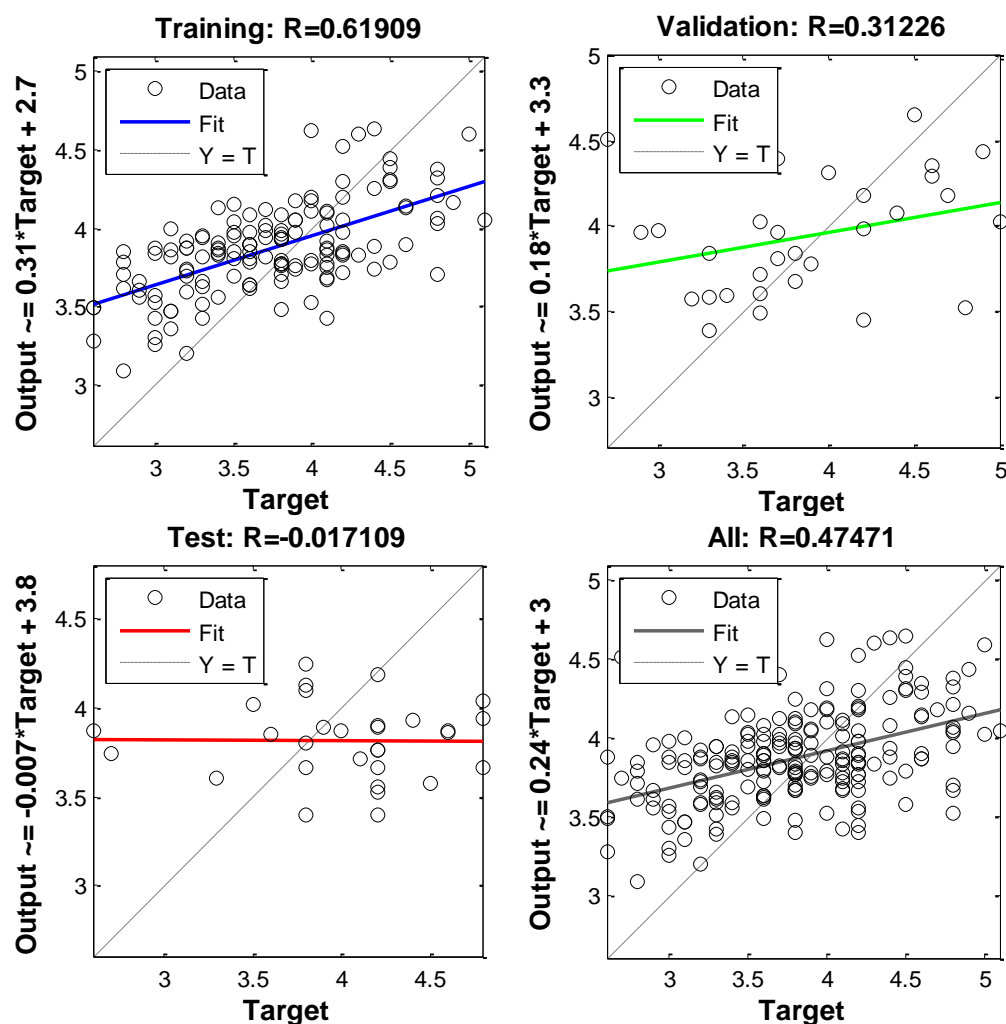


Figura 3-45. Autorregresión lineal de la función de entrenamiento Trainlm.

La estructura de la red neuronal para la estimación del modelo de fineza de malla No. 325 se muestra en la Figura 3-46. Cuenta con 70 pesos y 10 umbrales en la primera capa oculta y 10 pesos y un umbral en la segunda capa oculta.

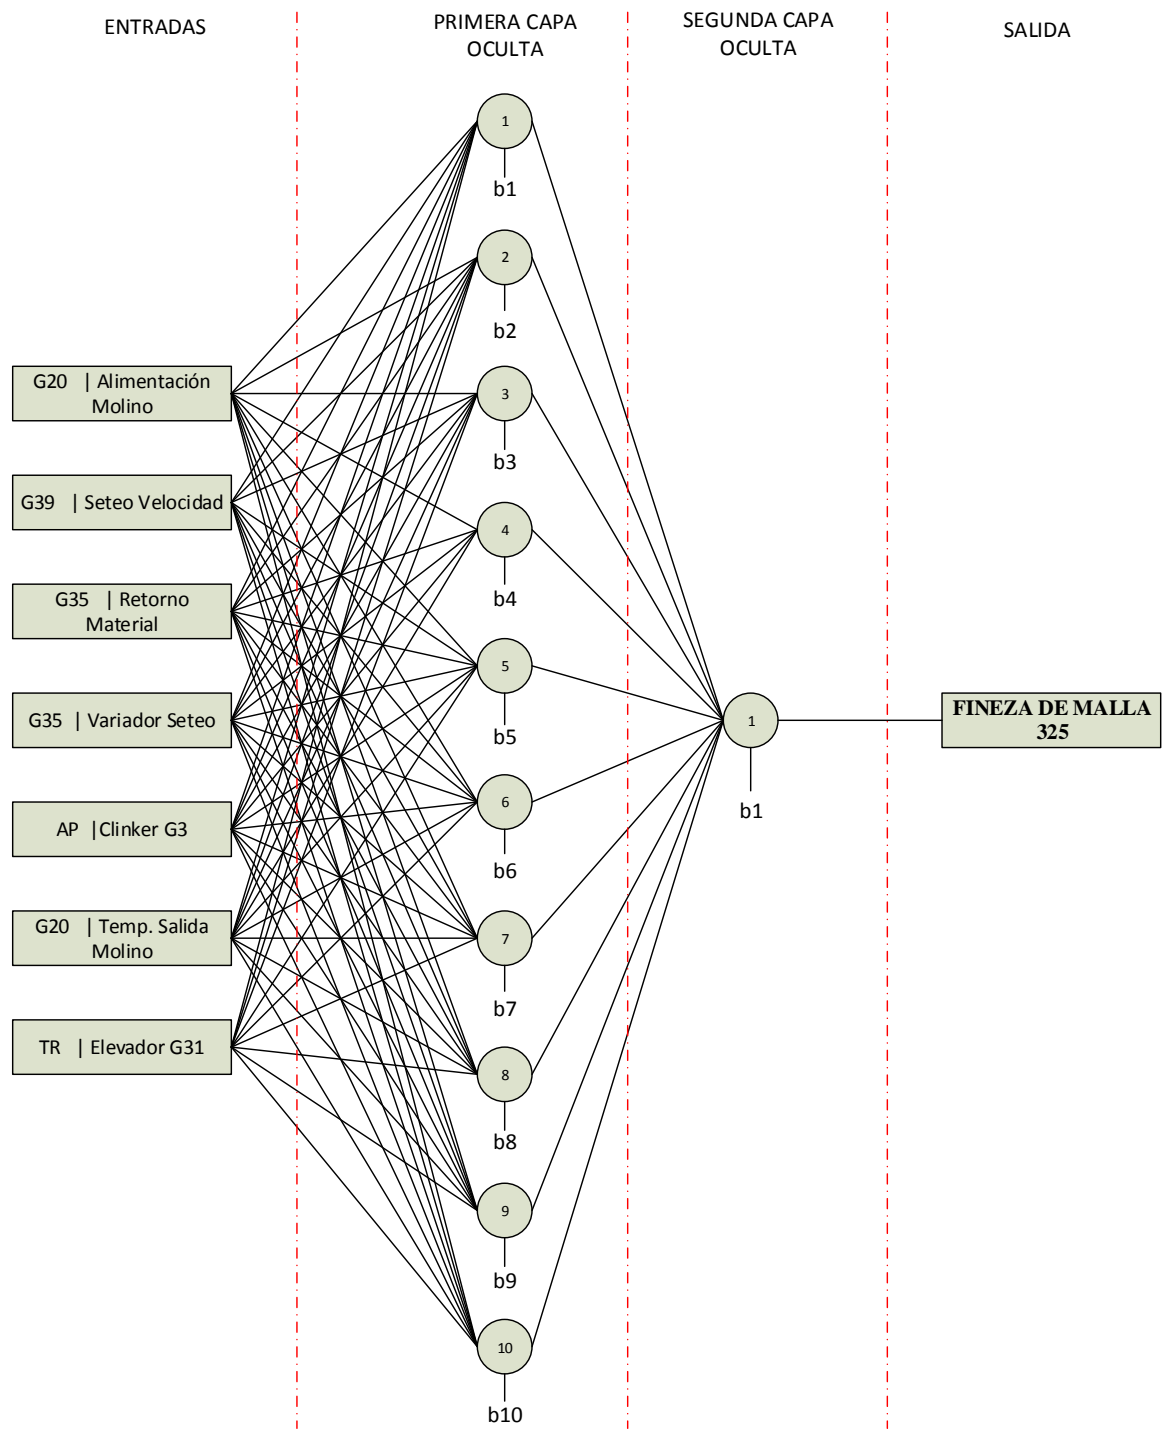


Figura 3-46. Red Neuronal para el modelo de predicción para la fineza de malla No. 325

La Tabla 3-15 muestra el análisis para la estimación del modelo de fineza de malla 325 con diferentes números de neuronas en la primera capa oculta. Los valores van desde 5 a 50 neuronas. El mejor modelo corresponde al coeficiente de autorregresión lineal más alto. Las estimaciones se realizaron tres veces debido a que los pesos y umbrales se inicializan de forma aleatoria. El promedio de R mayor representa el mejor modelo.

Tabla 3-15. Análisis de número de neuronas del modelo

#Neuronas	R			R promedio
	1	2	3	
5	0.24056	0.11515	0.14697	0.16756
10	0.38226	0.41554	0.47489	0.42423
15	0.22072	0.41307	0.30237	0.31205
20	0.50223	0.39722	0.5186	0.47268
25	0.377	0.49218	0.46677	0.44532
30	0.36028	0.33047	0.27048	0.32041
35	0.62294	0.58277	0.56929	0.59167
40	0.60594	0.56166	0.59796	0.58852
45	0.4631	0.56173	0.53132	0.51872
50	0.59204	0.4546	0.54796	0.53153

Los modelos estimados con 35 neuronas en la primera capa oculta presentan los mejores coeficientes R promedio. La estimación elegida tiene una R de 0.62294.

La Figura 3-47 presenta la autorregresión lineal del modelo en las fases de entrenamiento, validación y comprobación. La Figura 3-48 muestra la estimación del modelo en comparación con los datos reales de la planta.

Las funciones de activación han sido trabajadas con los valores por defecto, es decir, funciones tansigmodiales tanto para la primera capa oculta como para la segunda.

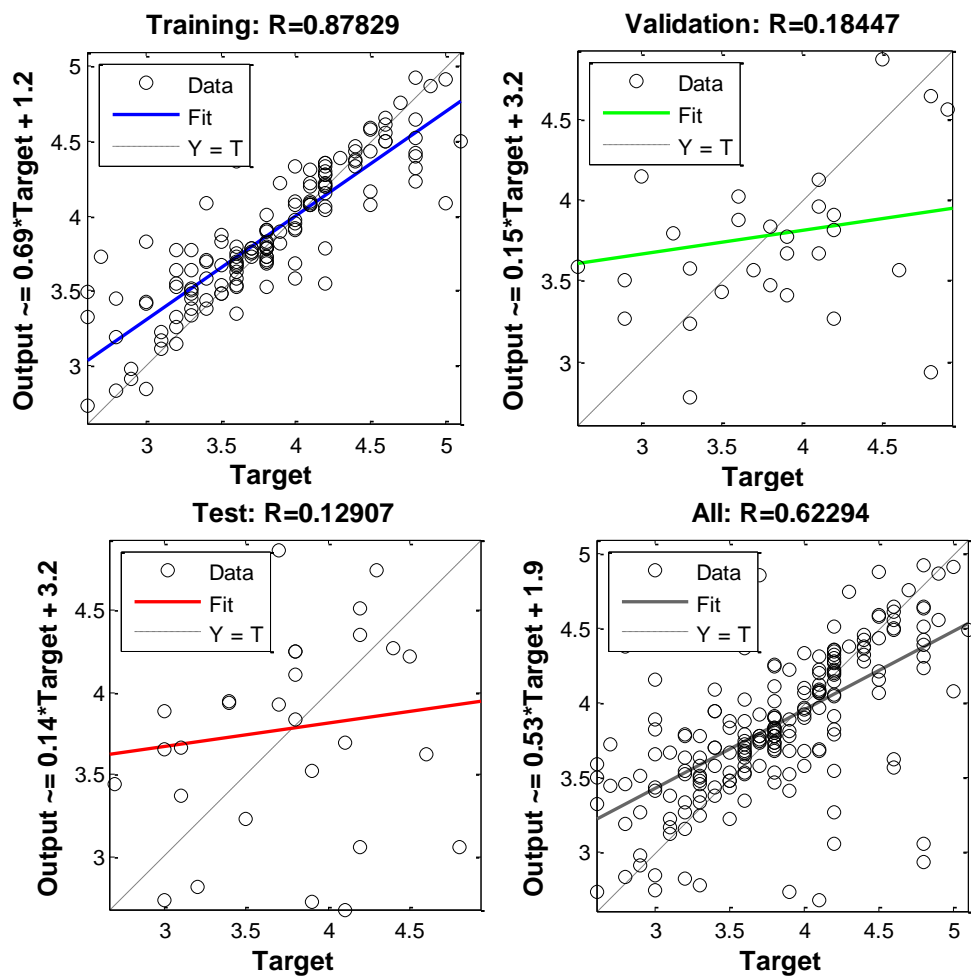


Figura 3-47. Autorregresión lineal del modelo de predicción con 45 neuronas




Figura 3-48. Modelo de predicción para el retenido de malla con 45 neuronas



La Tabla 3-16 muestra las combinaciones posibles entre las funciones de activación incorporadas en *MATLAB*. Además muestra el coeficiente de autorregresión lineal para cada combinación.

Tabla 3-16. Análisis de las funciones de transferencia del modelo

#	Capa Oculta 1	Capa Oculta 2	R			Rpromedio
			R1	R2	R3	
1	tansig	tansig	0.51256	0.62769	0.50786	0.54937
2	tansig	logsig	0.25694	0.26249	0.26038	0.25994
3	tansig	purelin	0.43784	0.49407	0.55204	0.49465
4	logsig	tansig	0.50571	0.52351	0.30907	0.4461
5	logsig	logsig	0.27434	0.25815	0.24602	0.2595
6	logsig	purelin	0.36736	0.38527	0.50812	0.42025
7	purelin	tansig	0.24331	0.37065	0.24067	0.28488
8	purelin	logsig	0.2611	0.2828	0.29793	0.28061
9	purelin	purelin	0.25739	0.29294	0.27812	0.27615

El mejor resultado es el conformado por la combinación tansigmoidal y tansigmoidal en la primera y segunda capa oculta respectivamente, con un coeficiente de autorregresión promedio de 0.54937, sin embargo el modelo elegido es el que posee un coeficiente de 0.62769 que representa el valor máximo.

El modelo final para la estimación del retenido de malla No. 325 está conformado por: 2 capas ocultas, 35 neuronas en la primera capa y una sola en la segunda. La función de activación tansigmoidal en la primera capa y en la segunda capa oculta. La función de entrenamiento utilizada es Trainlm. El modelo tiene una aproximación del 62.769%.

La autorregresión lineal R para las fases de entrenamiento, validación y comprobación se muestran en la Figura 3-49. La estimación del modelo propuesto en comparación del modelo real del sistema se observa en la Figura 3-50.

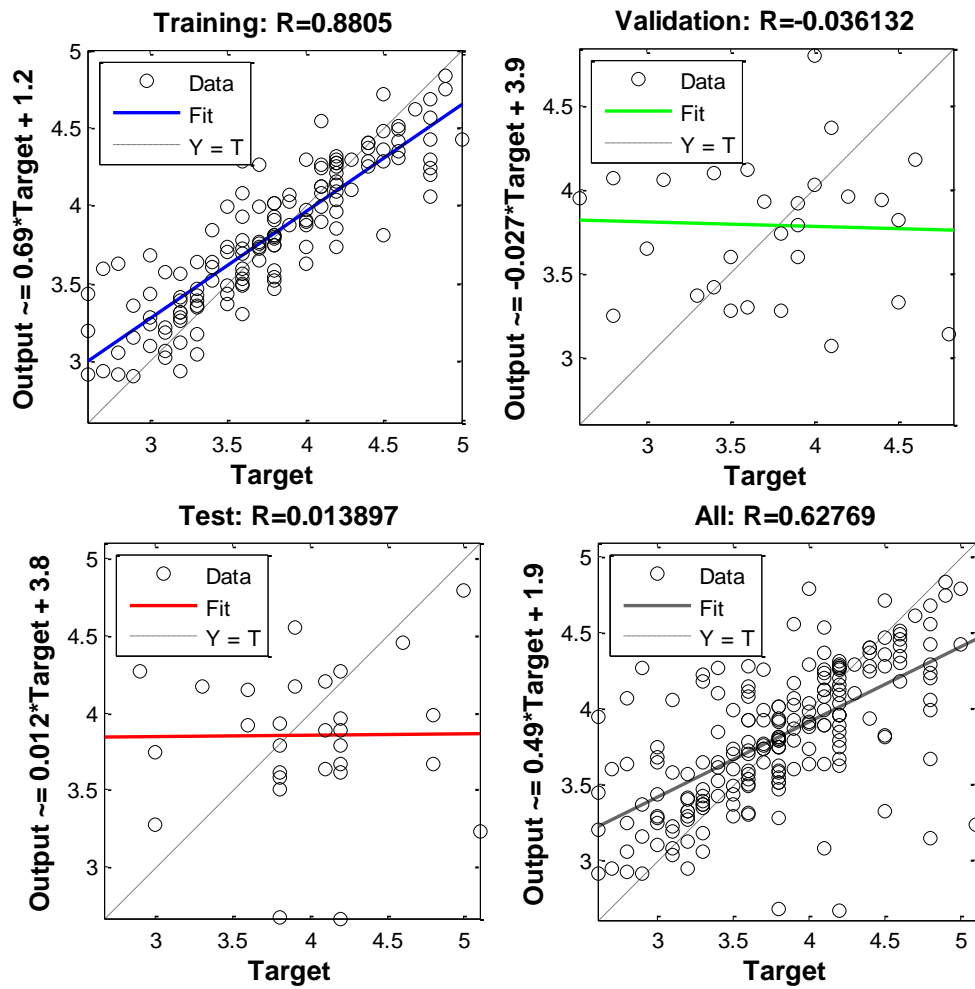


Figura 3-49. Autorregresión lineal del modelo con función de transferencia tansigoidal




Figura 3-50. Modelo de predicción con la función de transferencia tansigoidal



El modelo final para la estimación del retenido de malla está determinado por la siguiente ecuación:

$$\text{Modelo neuronal}_{\text{Fineza}} = f1\{W2 * [f1(w1 * X + b1)] + b2\} \quad (3-19)$$

Donde $W1, W2, b1$ y $b2$ son las matrices correspondientes a los pesos y umbrales mencionados anteriormente, $f1$ es la función de activación logsigmoidal y $f2$ es la función tansigmoidal. X es el vector de entradas dado por:

$$X = \begin{bmatrix} X1: G20 | Alimentación Molino \\ X2: G39 | Seteo Velocidad \\ X3: G35 | Retorno Material \\ X4: G35 | Variador Seteo \\ X5: AP | Clinker G3 \\ X6: TR | Temp. Salida Molino \\ X7: TR | Elevador G31 \end{bmatrix}$$

3.9 Modelos neurodifusos

En esta sección se presentan los modelos neurodifusos del Blaine y del de retenido de malla No. 325.

3.9.1 Modelos neurodifusos para las variables de calidad

Las variables de operación (Tabla 3-10) son las entradas del sistema y la salida es la variable de calidad correspondiente. El número de variables para desarrollar el modelo es igual a siete.

Los modelos se desarrollan con los valores por defecto que inicializa la herramienta *anfisedit* de *MATLAB*. En primera instancia se trabaja con 10 iteraciones y 2 funciones de membresía. El tipo de aprendizaje es el híbrido.

Se cuenta con un total de 221 muestras después del tratamiento de los datos. Para la etapa de aprendizaje se utilizarán 171 muestras mientras que las 50 restantes se ocuparán para la validación.

3.9.1.1 Proceso de entrenamiento para la creación del modelo neurodifuso.

El proceso de entrenamiento para la estimación de los modelos de Blaine y fineza de retenido de malla mediante la creación de sistemas neurodifusos tipo ANFIS se realiza de acuerdo al siguiente procedimiento:

1. Crear el sistema neurodifuso para los modelos de Blaine y retenido de malla con los valores correspondientes a la planta de cemento. Los valores de entrada son las variables de operación usadas en el desarrollo de la modelación estadística y dinámica. La Figura 3-51 muestra la herramienta anfisedit de *MATLAB* y su estructura de creación de los sistemas neurodifusos.

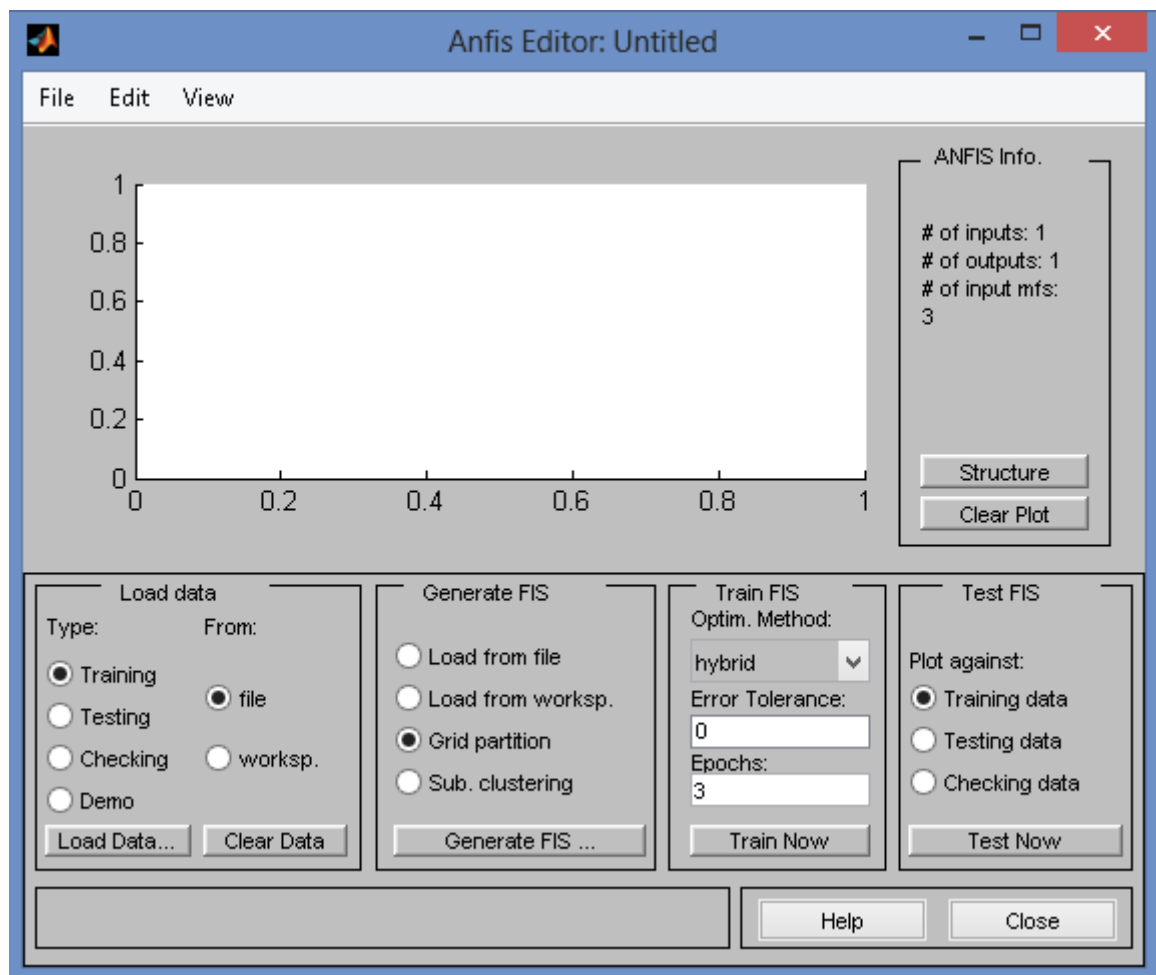


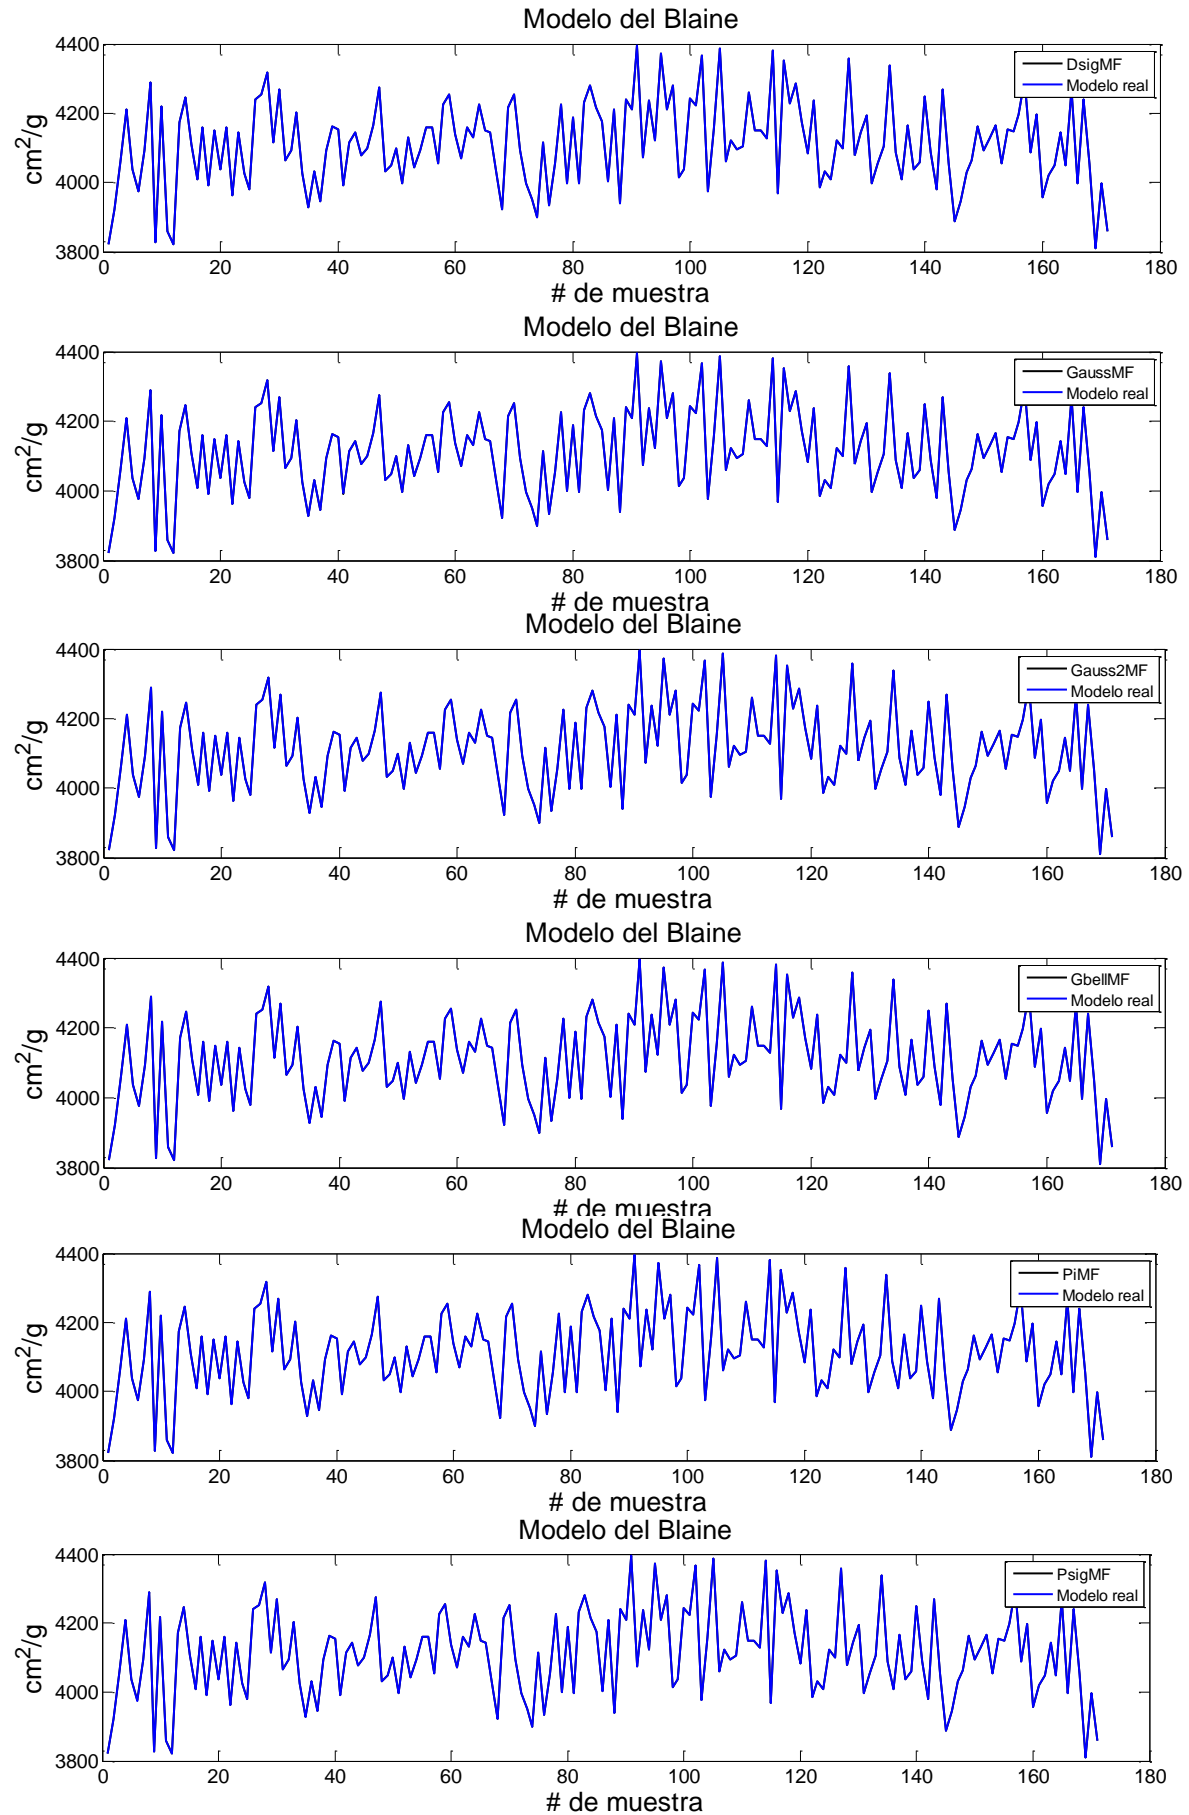
Figura 3-51. Creación del sistema neurodifuso



2. Entrenar al sistema con los datos de entrenamiento correspondientes para cada una de las funciones de membresía: *dsigMF*, *gaussMF*, *gauss2MF*, *gbellMF*, *piMF*, *psigMF*, *trapMF* y *triMF*.
3. Realizar la etapa de validación con el set correspondiente a la validación de los sistemas para cada una de las funciones de membresía mencionadas.
4. Determinar los valores de media, desviación estándar e histogramas del error, así como su error de entrenamiento, tanto para la fase de entrenamiento como para la de validación. La herramienta *anfisedit* proporciona el valor del error de entrenamiento. Escoger el modelo con mejores resultados.
5. Entrenar al sistema con diferente número de variables de entrada, inicialmente el número de variables de operación son siete. Las variables para la modelación del Blaine y el retenido de malla se presentan en la Tabla 3-10. Se varía el número de variables disminuyendo hasta un mínimo de cuatro, que son las variables por defecto presentadas en la Tabla 3-7.
6. Realizar la etapa de validación con el set correspondiente a la validación de los sistemas para cada uno de los modelos desarrollados.
7. Determinar los valores de media, desviación estándar e histogramas del error y su error de entrenamiento para la fase de entrenamiento como para la de validación. Escoger el modelo con mejores resultados.
8. Entrenar al sistema con la variación de los parámetros: número de funciones de membresía y número de iteraciones.
9. Determinar los valores de media, desviación estándar e histogramas del error y su error de entrenamiento para la fase de entrenamiento como para la de validación. Escoger el modelo con mejores resultados.

3.9.1.2 Modelo neurodifuso para el Blaine

El primer entrenamiento es realizado utilizando las 7 indicadas en la Tabla 3-10. La Figura 3-52 presenta las estimaciones de los modelos de predicción realizados con cada una de las funciones de membresía.






Figura 3-52. Estimación de modelos de predicción en fase entrenamiento con 7 variables

La media y desviación estándar respecto del error entre el modelo real de la planta y el modelo estimado se observa en la Tabla 3-17. Además se presenta el error de entrenamiento obtenido con la herramienta *anfisedit*.

Tabla 3-17. Análisis de funciones de membresía en fase entrenamiento con 7 variables

Función de membresía	Media	Desviación estándar	Error de entrenamiento
DsigMF	-0.0011	0.0112	0.646
GaussMF	0.000090328	0.0641	2.798
Gauss2MF	0.00027343	0.0064	0.021
GbelIMF	0.000072052	0.0172	0.0648
PiMF	-0.000091975	0.0045	0.0051
PsigMF	0.0016	0.0122	0.0028
TrapMF	0.00023709	0.0028	0.01115
TriMF	-0.00013568	0.6465	0.0029

La Figura 3-53 muestra los histogramas con respecto al error entre el modelo real y el estimado.


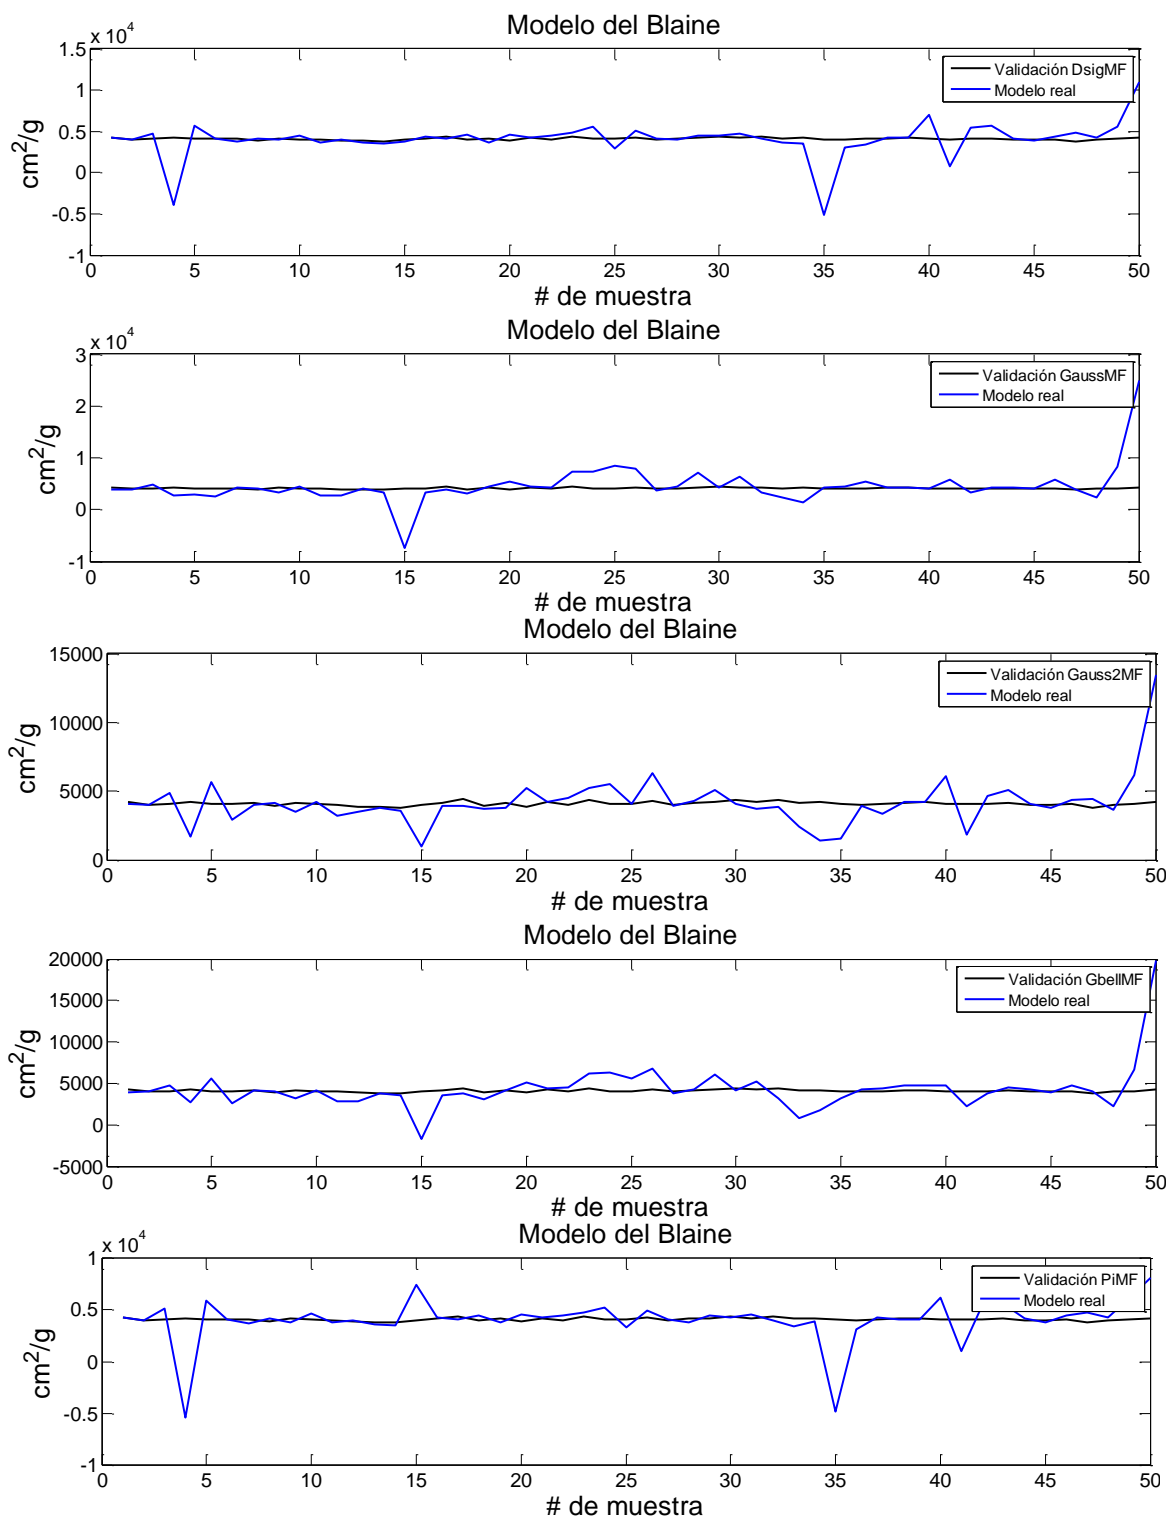


Figura 3-53. Histograma del error en la fase de entrenamiento con 7 variables

El error cometido en la fase de entrenamiento para todas las funciones de membresía es prácticamente nulo, a excepción de la función gaussiana. GbellMF presenta la mejor media e histograma del error. TrapMF tiene la menor desviación estándar mientras que Gauss2MF tiene el menor error de entrenamiento. Los modelos de predicción desarrollados en la etapa de validación se muestran en la Figura 3-54 con un set de datos diferente al utilizado en el entrenamiento.






Figura 3-54. Estimación de modelos de predicción en fase validación con 7 variables

La Tabla 3-18 presenta análogamente el análisis en la etapa de validación.

Tabla 3-18. Análisis de funciones de membresía en fase validación con 7 variables

Función de membresía	Media	Desviación Estándar
DsigMF	65.0233	2182.3
GaussMF	-486.184	3700.2
Gauss2MF	-71.1027	1749.9
GbelMF	-207.9987	2655.6
PiMF	55.5732	2188.1
PsigMF	56.4711	2173.2
TrapMF	175.6348	1877.4
TriMF	-1646.2	6218.8

La Figura 3-55 muestra el histograma del error en la etapa de validación con 7 variables.

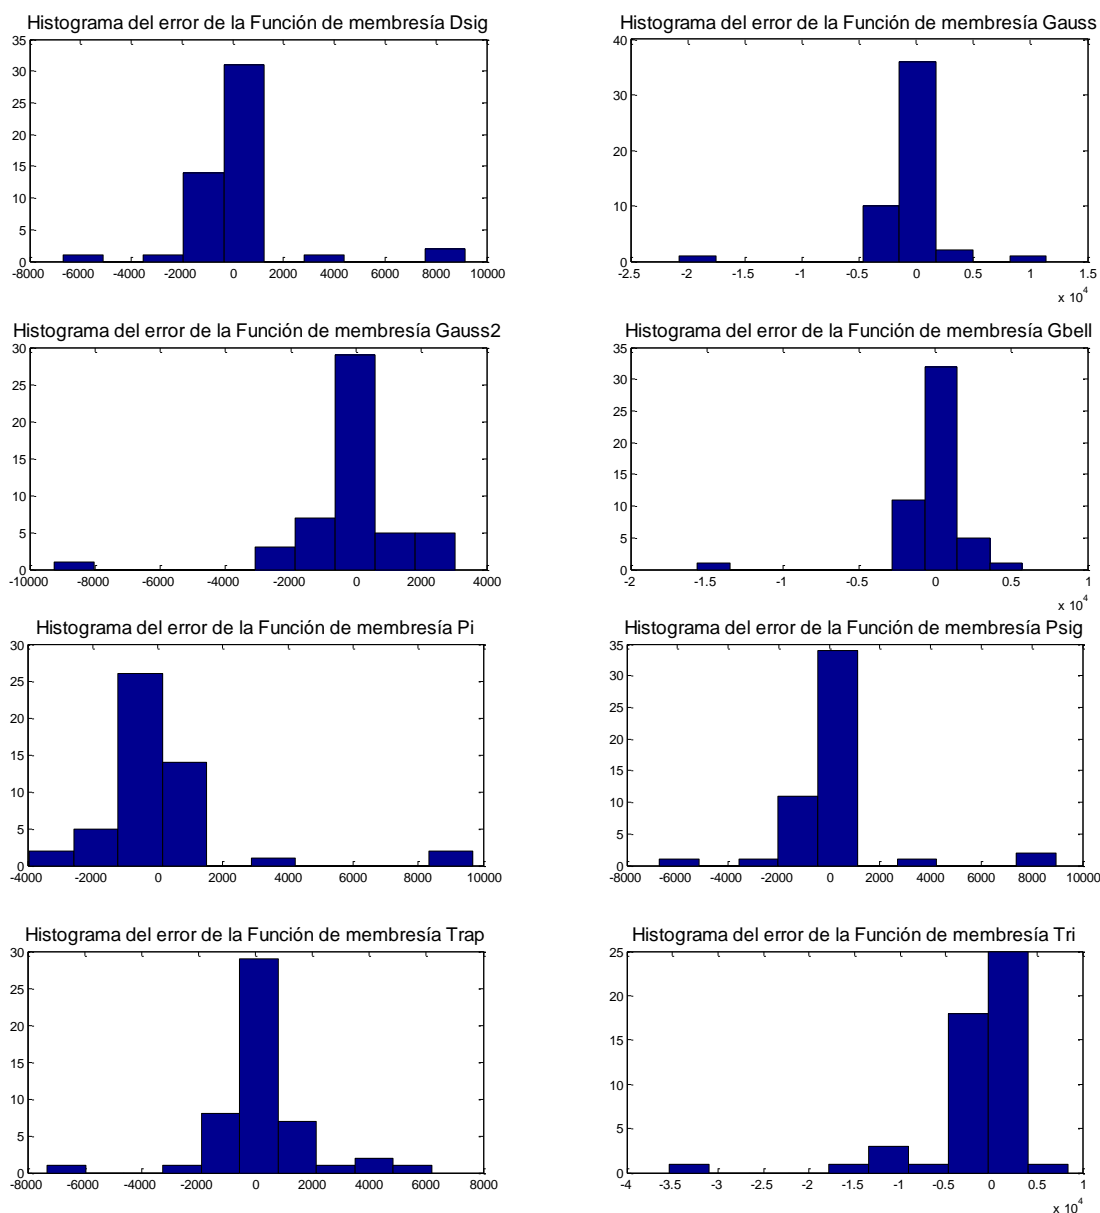


Figura 3-55. Histograma del error en la fase de validación con 7 variables

Los resultados de predicción se encuentran alejados de los valores reales. PiMF presenta la media del error más cercana a cero. Gauss2MF tiene la menor desviación estándar de todas las funciones de membresía mientras que TrapMF muestra el mejor histograma del error. El modelo que mejor se acopla para la modelación difusa del Blaine con 7 variables es la función Gauss2MF.

La herramienta *anfisedit* proporciona una regla por cada una de las combinaciones por lo que se tiene n^i combinaciones, donde n es el número de funciones de membresía e i es el número de variables de entrada. Para este caso el número de entradas es 7 y el de funciones de membresía 2 por lo que cuenta con 128 reglas para el modelo neurodifuso propuesto. El número de entradas aumenta la complejidad de la estructura, por lo cual se propone disminuir, en la entrada, el número de variables de operación.

Se eliminarán las variables que presenten una menor desviación estándar, que se encuentran dentro de un margen de valores menor. El hecho que tengan una menor desviación estándar significa que varían en menor cantidad por lo que afectan menos el comportamiento del modelo de la planta. El proceso se lo realiza hasta un mínimo de 4 variables que es el número mínimo de variables por defecto (Tabla 3-7).

La primera variable eliminada es la correspondiente a la temperatura del cojinete sur que tiene una desviación estándar de 1.33. La segunda es la Clinker G3 con desviación típica de 2.65 y por último la variable de llenado de silo con desviación de 9.08. Los modelos propuestos tienen 6, 5 y 4 variables respectivamente.

El proceso a seguir será el desarrollado anteriormente con el modelo de 7 variables. El hecho de usar 6 variables de entrada conlleva a 2^6 combinaciones equivalentes a 64 reglas para la modelación.

La Tabla 3-19 presenta el análisis estadístico de los modelos desarrollados con respecto a la fase de entrenamiento con 6 variables.

DsigMF presenta la mejor media del error y TrapMF la menor desviación estándar. TriMF tiene el mejor histograma del error.

Tabla 3-19. Análisis de funciones de membresía en fase entrenamiento con 6 variables

Funciones de membresía	Media	Desviación Estándar	Error de entrenamiento
DsigMF	0.000074793	0.5105	0.50902
GaussMF	-0.00080313	3.5236	3.5662
Gauss2MF	-0.001	0.3662	0.3651
GbelIMF	0.001	1.1147	1.1345
PiMF	-0.0011	0.2923	0.29141
PsigMF	-0.0039	0.5696	0.56795
TrapMF	0.00036556	0.0488	0.0498
TriMF	0.00072696	42.3324	42.346

A continuación se presenta la fase de validación para los modelos desarrollados con 6 variables. La Tabla 3-20 presenta su análisis estadístico.

Tabla 3-20. Análisis de funciones de membresía en fase validación con 6 variables

Funciones de membresía	Media	Desviación Estándar
DsigMF	10917	44896
GaussMF	1532	6954.1
Gauss2MF	6085.2	20966
GbelIMF	2739.5	9695.4
PiMF	-1774.5	9071.5
PsigMF	10309	41638
TrapMF	-2109	6462
TriMF	734.6261	3596.3

En la fase de validación con 6 variables los resultados son: TriMF tiene la media más cercana a cero y la menor desviación estándar del error. El mejor histograma del error se observa en la función PiMF.

El modelo estimado con mejores resultados con 6 variables de entrada es la función de membresía triangular, sin embargo son resultados muy erróneos.

El siguiente modelo utiliza 5 variables de entrada. Primero se observa su fase de entrenamiento y luego la de validación. El número de reglas baja a 2^5 combinaciones equivalente a 32 reglas neurodifusas.

El análisis de la media y desviación estándar del error y el error de entrenamiento cometido se aprecia en la Tabla 3-21.

Tabla 3-21. Análisis de funciones de membresía en fase entrenamiento con 5 variables

Funciones de membresía	Media	Desviación estándar	Error de entrenamiento
DsigMF	-0.00014112	62.1983	62.1098
GaussMF	0.00012688	69.7094	69.5082
Gauss2MF	0.00041294	66.2696	66.1021
GbellMF	-0.00019332	68.6181	68.434
PiMF	-0.00014482	64.2350	64.0659
PsigMF	0.00011185	62.1983	62.1098
TrapMF	-0.0003113	65.6141	65.4388
TriMF	-0.00012841	82.1242	82.0163

En la etapa de entrenamiento con 5 variables se observa que PsigMF tiene la media del error más próxima a cero, la menor desviación estándar y error de entrenamiento. Los valores con respecto de la función DsigMF son prácticamente los mismos.

A continuación se realiza la etapa de validación con 5 variables. El análisis estadístico se observa en la Tabla 3-22.

Tabla 3-22. Análisis de funciones de membresía en fase validación con 5 variables

Funciones de membresía	Media	Desviación estándar
DsigMF	-101.0881	909.7219
GaussMF	-123.6143	883.6572
Gauss2MF	-29.0533	866.1759
GbellMF	-86.8928	956.9946
PiMF	198.1916	1528.4
PsigMF	-101.0566	909.7785
TrapMF	206.6654	1410.1
TriMF	261.5038	3178.8

El modelo escogido para la modelación con 5 variables es Gauss2MF ya que en la etapa de validación presenta la mejor media y desviación estándar de todas las funciones de pertenencia. PsigMF y DsigMF presentan los mejores histogramas del error. Los modelos desarrollados son pobres en cuanto a su valor de error cuadrático medio que es el mismo que la desviación estándar.

El último modelo desarrollado para la estimación del Blaine tiene 4 variables de entrada que son las que establecen por defecto. Conlleva a 2^4 combinaciones para las reglas neurodifusas, es decir, 16. La Tabla 3-23 presenta el análisis de las funciones de pertenencia.

Tabla 3-23. Análisis de funciones de membresía en fase entrenamiento con 4 variables

Funciones de membresía	Media	Desviación estándar	Error de entrenamiento
DsigMF	0.000049525	96.2753	96.0234
GaussMF	-0.000065924	95.4727	95.1978
Gauss2MF	0.00027655	96.0242	95.7505
GbelIMF	-0.00010781	95.7095	95.4347
PiMF	-0.00018317	96.3891	96.1118
PsigMF	0.00012522	96.2754	96.0234
TrapMF	-0.000003079	96.4670	96.1978
TriMF	0.00011923	99.2862	98.9982

TrapMF tiene la mejor media del error mientras que la menor desviación estándar y error de entrenamiento tiene la función gaussiana GaussMF.

Finalmente se presenta la fase de validación con 4 variables. La Tabla 3-24 muestra la media y desviación estándar del error de la fase de validación correspondiente a la modelación con 4 variables.

Tabla 3-24. Análisis de funciones de membresía en fase validación con 4 variables

Mf	Media	Desviación Estándar
DsigMF	-284.0431	1295.3
GaussMF	-62.4187	2543.8
Gauss2MF	-495.0867	3753.7
GbelIMF	-50.4783	1844.6
PiMF	-356.5284	1408.9
PsigMF	-284.0157	1295.2
TrapMF	-212.218	1835.6
TriMF	-155.7967	934.2207

Por último en la fase de validación GbelIMF tiene la media del error más cercana a cero. PsigMF presenta la menor desviación típica y GbelIMF el mejor histograma del error. El modelo elegido en la modelación con 4 variables es PsigMF.

A continuación se realiza la comparación de los mejores modelos de predicción para cada uno de los números de variables desde 7 hasta 4. La Tabla 3-25 contiene el resumen de los modelos escogidos tanto en la fase de entrenamiento como en la de validación.

Tabla 3-25. Comparación de las funciones de pertenencia

#Variables	Función de membresía	Etap	Media	Desviación estándar
------------	----------------------	------	-------	---------------------

7	Gauss2MF	Entrenamiento	0,00027343	0,0064
		Validación	-71,1027	1749,9
6	TriMF	Entrenamiento	0,00072696	42,3324
		Validación	734,6261	3596,3
5	Gauss2MF	Entrenamiento	0,00041294	66,2696
		Validación	-29,0533	866,1759
4	PsigMF	Entrenamiento	0,00012522	96,2754
		Validación	-284,0157	1295,2

Se observa que a medida que el número de variables aumenta el error cuadrático medio o desviación estándar aumenta, sin embargo se aprecia que la función que presenta el menor error en la etapa de validación es la función de membresía Gauss2MF con 5 variables de entrada. Este será el modelo neurodifuso seleccionado para comparar con las demás técnicas de estimación del Blaine. A continuación se realiza la variación del parámetro correspondiente al número de iteraciones con fin de mejorar la estimación del modelo.

La Tabla 3-26 presenta el resumen de la media y desviación estándar para el número de iteraciones desde 100, 200, 300, 400 y 500 en la etapa de validación. Se realizó la prueba hasta 500 iteraciones ya que a partir de ese número el error convergió en 52.69.

Tabla 3-26. Comparación de los modelos según el número de iteraciones

Número de iteraciones	Media	Desviación estándar
100	-30.0289	927.152
200	20.3138	1120.4
300	258.5977	1923.7
400	740.4358	4292
500	1327.4	7358

Con 200 iteraciones mejora el valor de la media, pero el valor de la desviación estándar empeora. El modelo escogido es el que se realizó inicialmente con 10 iteraciones.

El modelo final resultante tanto para la etapa de entrenamiento como para la de validación se observa en la Figura 3-56.




Figura 3-56. Estimación del modelo de predicción final del Blaine sin corrección

Los valores de media y desviación estándar para el modelo total de estimación del Blaine son:

$$\mu = -6.5728 ; \quad \sigma = 413.0926$$

Se observa que el modelo tiene valores no posibles para la estimación del Blaine. La obtención del modelo definitivo se realiza en el capítulo 4 en la sección de corrección de modelos neurodifusos. Finalmente la Figura 3-57 muestra la arquitectura del modelo neurodifuso desarrollado.

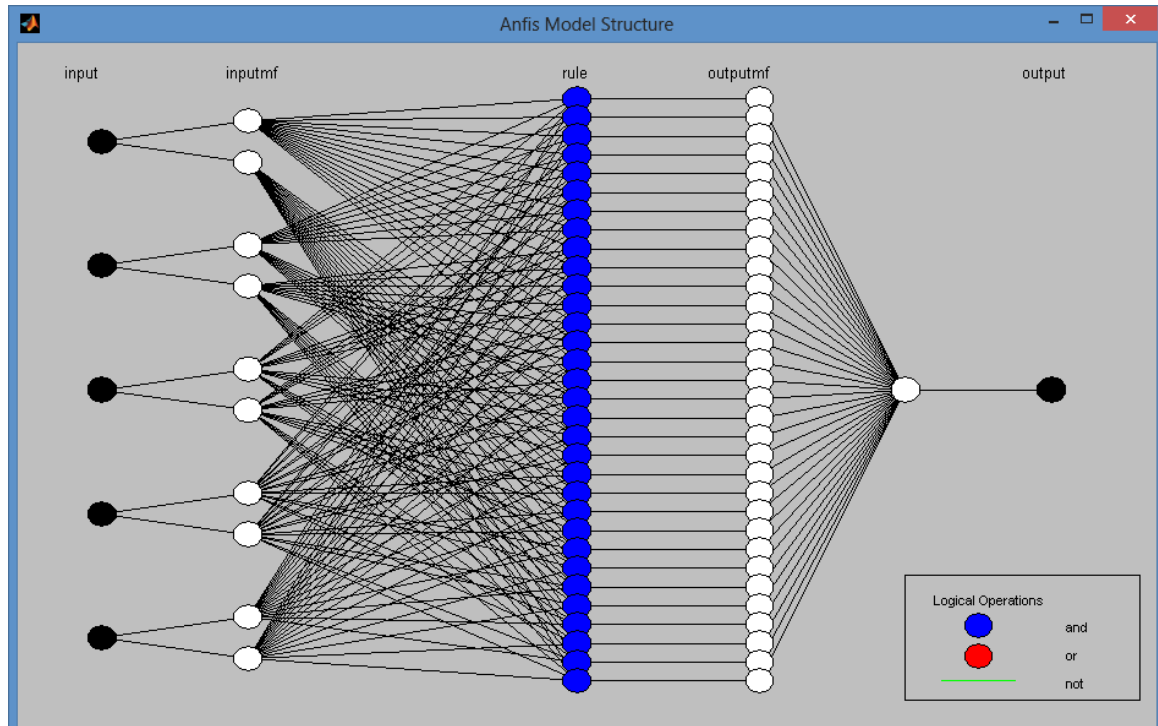



Figura 3-57. Arquitectura del modelo neurodifuso del Blaine

3.9.1.3 Modelo neurodifuso del retenido de malla No. 325

El proceso para la determinación del modelo neurodifuso del retenido de malla es el mismo que para la modelación del Blaine. Las etapas de entrenamiento y validación para cada número de variables desde 7 (Tabla 3-10) hasta 4 (Tabla 3-7) se muestran a continuación. La primera variable en ser eliminada será Clinker G3 con desviación estándar de 2.65, la segunda Amperaje elevador G31 con desviación típica de 2.89 y por último Temperatura salida molino con 6.43.

Los modelos de predicción para todas las funciones de membresía en comparación con el modelo real se observan en la Figura 3-58.






Figura 3-58. Estimación de modelos de predicción en fase entrenamiento con 7 variables

La Tabla 3-27 presenta el análisis estadístico correspondiente a la fase de entrenamiento con 7 variables.

Tabla 3-27. Análisis de funciones de membresía en fase entrenamiento con 7 variables

Funciones de membresía	Media	Desviación estándar	Error de entrenamiento
DsigMF	-0.000135	0.0002898	0.000319
GaussMF	0.0000014	0.0002293	0.000229
Gauss2MF	-0.000028	0.0000501	0.000057
GbelIMF	0.0000035	0.0000709	0.000071
PiMF	0.0000012	0.0000393	0.000039
PsigMF	-0.000142	0.0002526	0.000289
TrapMF	-0.00000099	0.0000179	0.000017916
TriMF	0.000000031	0.0024	0.0024135

Los histogramas del error de las funciones de membresía se observan en la Figura 3-59.

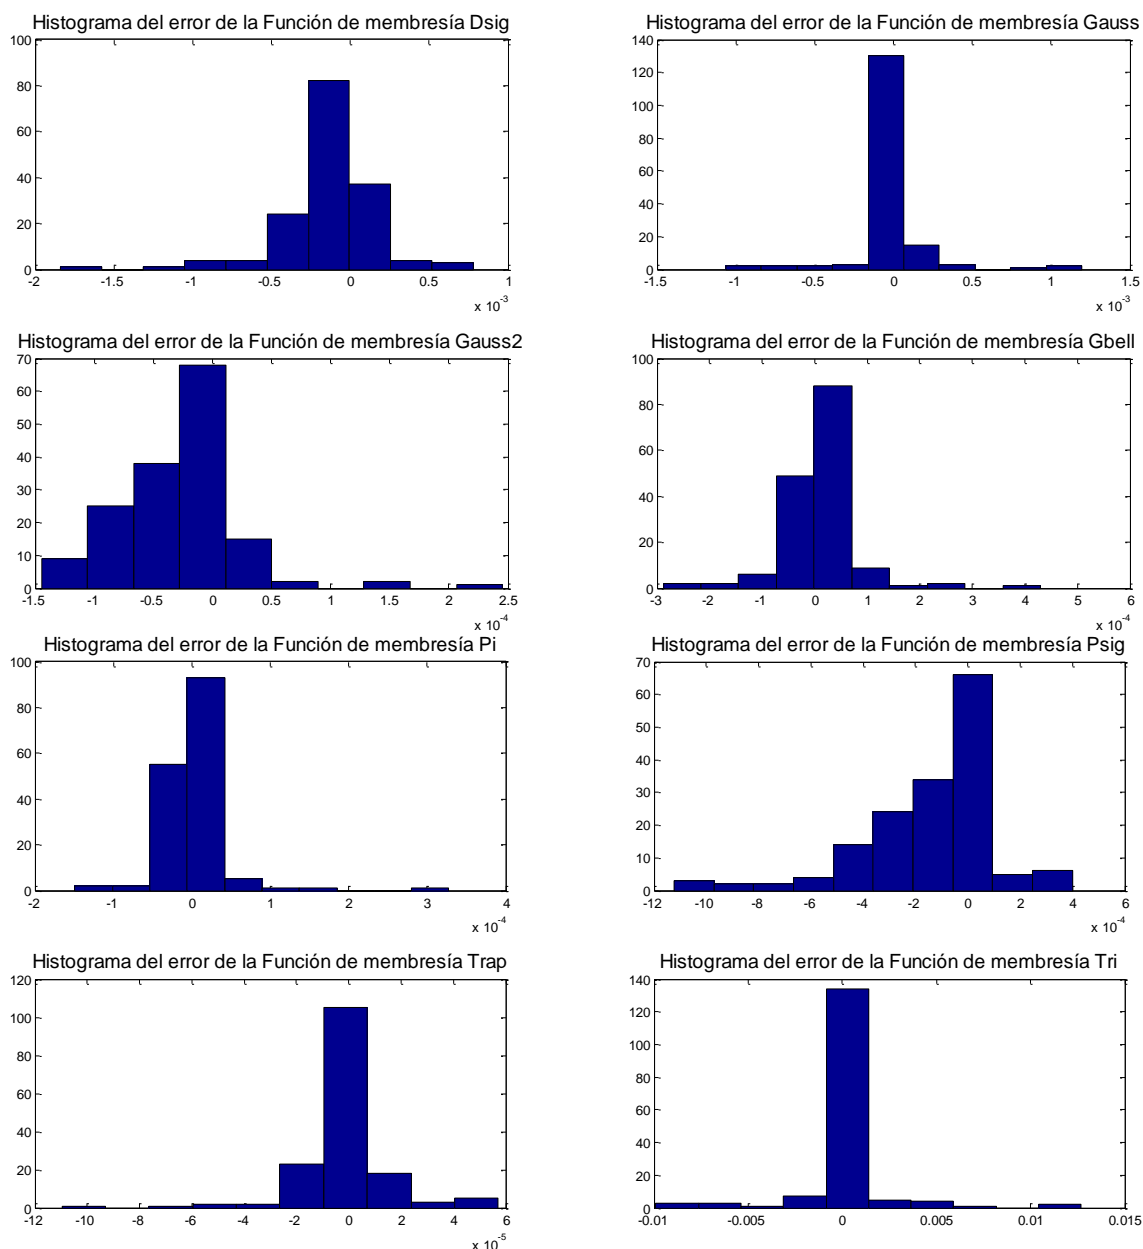



Figura 3-59. Histograma del error en la fase de entrenamiento con 7 variables

TriMF presenta la mejor media e histograma del error. TrapMF tiene la menor desviación estándar y el menor error de entrenamiento.

A continuación se presenta la etapa de validación. La Figura 3-60 y la Figura 3-61 muestran los modelos estimados de predicción y los histogramas del error respectivamente con 7 variables.






Figura 3-60. Estimación de modelos de predicción en fase validación con 7 variables

La media y desviación típica del error en la fase de validación se observa en la Tabla 3-28.

Tabla 3-28. Análisis de funciones de membresía en fase validación con 7 variables

Funciones de membresía	Media	Desviación Estándar
DsigMF	2.5254	9.8109
GaussMF	-0.0694	8.2583
Gauss2MF	0.8610	5.8095
GbellMF	-1.1754	5.5466
PiMF	1.9906	7.8027
PsigMF	2.5254	9.8109
TrapMF	-1.0648	5.95
TriMF	0.4581	22.6853

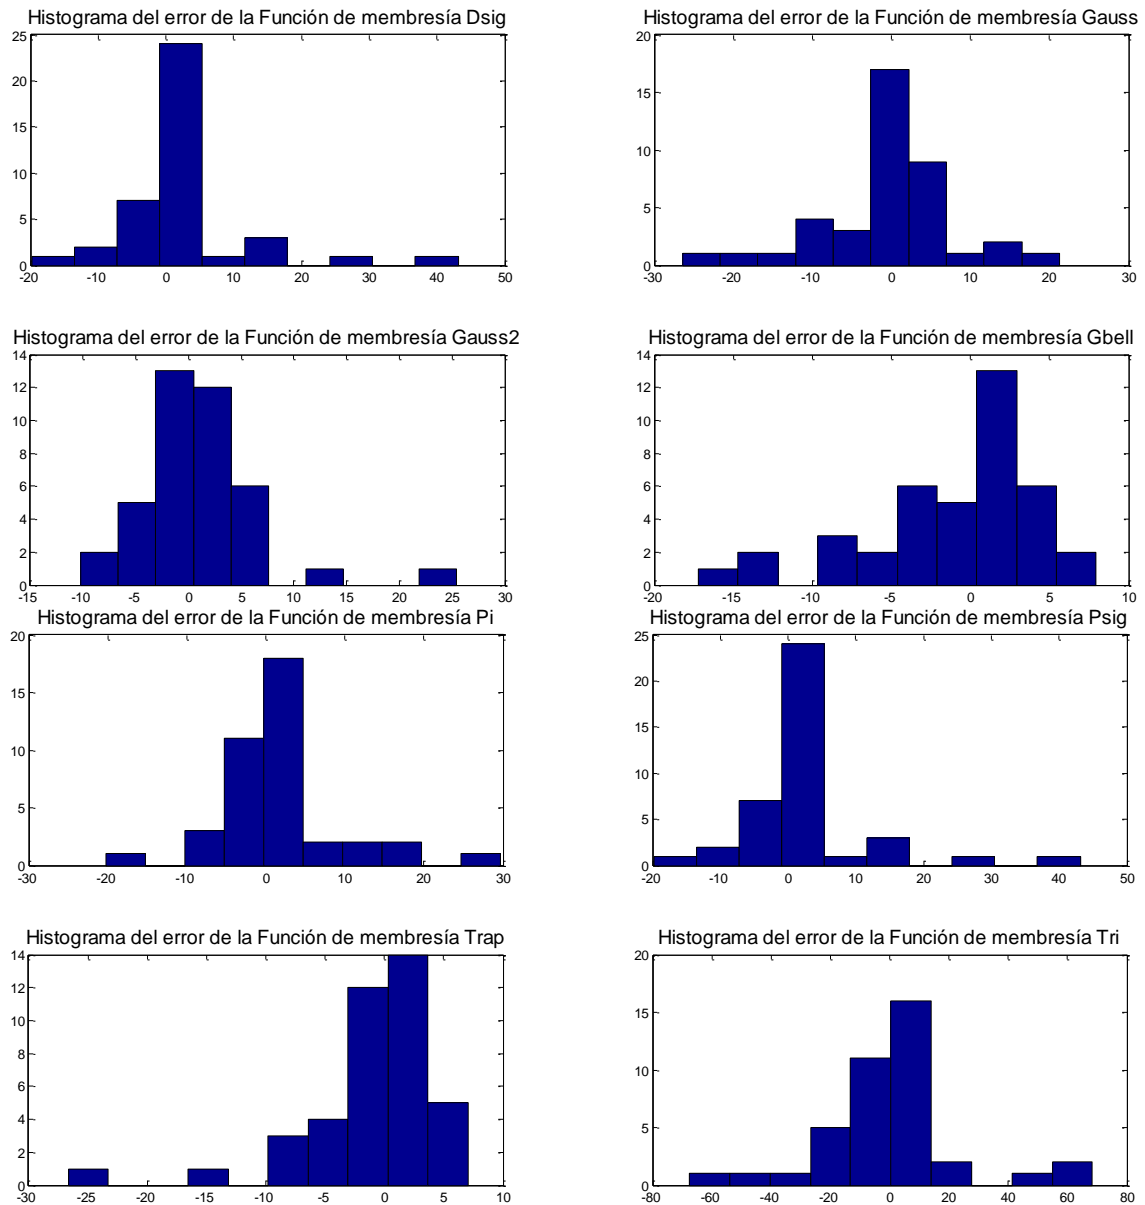


Figura 3-61. Histograma del error en la fase de validación con 7 variables

Los resultados de la etapa de validación con 7 variables son: GaussMF presenta la mejor media del error mientras que GbellMF tiene la menor desviación estándar que es equivalente al menor error cuadrático medio. El modelo escogido para la modelación con 7 variables es el de la función GbellMF.

La estimación del modelo de predicción con 6 variables se muestra a continuación. La Tabla 3-29 presenta la comparación de la media y desviación estándar del error de las funciones de membresía. Además se presenta su error de entrenamiento.

Tabla 3-29. Análisis de funciones de membresía en fase entrenamiento con 6 variables

Funciones de membresía	Media	Desviación estándar	Error de entrenamiento
DsigMF	0.00004467	0.038	0.038898
GaussMF	-0.0000062178	0.0696	0.069595
Gauss2MF	-0.000023339	0.0216	0.021733
GbellMF	0.00000090491	0.0442	0.044314
PiMF	-0.00008412	0.1107	0.11039
PsigMF	0.000047018	0.0388	0.039427
TrapMF	0.0000027854	0.0683	0.068271
TriMF	-0.0000047337	0.1755	0.17558

GbellMF presenta la mejor media del error. Gauss2MF tiene la menor desviación estándar y error de entrenamiento. TriMF muestra un mejor histograma del error.

La fase de validación con 6 variables es la siguiente: la Tabla 3-30 el análisis estadístico de los modelos para cada función de membresía.

Tabla 3-30. Análisis de funciones de membresía en fase validación con 6 variables

Funciones de membresía	Media	Desviación estándar
DsigMF	-7.3252	41.1407
GaussMF	1.0097	17.3944
Gauss2MF	-4.1135	28.8741
GbellMF	3.9053	27.3048
PiMF	-13.0033	68.9236
PsigMF	-7.8362	40.5596
TrapMF	-1.7125	21.2584
TriMF	-5.2218	25.1141

GaussMF presenta los mejores resultados de media y desviación estándar del error. La función elegida para la modelación con 6 variables es GaussMF. El entrenamiento con 5 variables muestra en la Tabla 3-31 el análisis estadístico para cada función de membresía.

Tabla 3-31. Análisis de funciones de membresía en fase entrenamiento con 5 variables

Funciones de membresía	Media	Desviación estándar	Error de entrenamiento
DsigMF	-0.0000051913	0.2999	0.29965
GaussMF	-0.0000031446	0.3135	0.31253
Gauss2MF	0.000011291	0.2977	0.29683
GbellMF	0.00000561	0.3084	0.30751
PiMF	0.000014691	0.2993	0.29858
PsigMF	-0.0000063111	0.2999	0.29965
TrapMF	0.0000046344	0.2916	0.29077
TriMF	0.0000027787	0.3597	0.35977

La fase de entrenamiento determina que TriMF tiene la mejor media del error mientras que TrapMF presenta el menor error de entrenamiento y desviación estándar. GaussMF muestra un mejor histograma.

La media y desviación típica de la fase de validación con 5 variables se observa en la Tabla 3-32.

Tabla 3-32. Análisis de funciones de membresía en fase validación con 5 variables

Funciones de membresía	Media	Desviación estándar
DsigMF	-2.8873	34.7453
GaussMF	-1.8207	19.5681
Gauss2MF	-1.3233	34.0917
GbellMF	-6.4536	45.7445
PiMF	-2.774	25.5215
PsigMF	-2.8906	34.7665
TrapMF	3.2657	8.3539
TriMF	1.9789	9.6143

TrapMF es la función escogida para la predicción del modelo con 5 variables debido a que presenta la menor desviación y el mejor histograma. Gauss2MF tiene la mejor media.

Finalmente se presenta la modelación con 4 variables, primero la etapa de entrenamiento con el análisis estadístico en la Tabla 3-33.

Tabla 3-33. Análisis de funciones de membresía en fase entrenamiento con 4 variables

Funciones de membresía	Media	Desviación estándar	Error de entrenamiento
DsigMF	-0.00000011365	0.4270	0.42591
GaussMF	0.0000010628	0.4359	0.4346
Gauss2MF	-0.00000055234	0.4301	0.4289
GbellMF	0.00000031344	0.4332	0.43192
PiMF	-0.00000009763	0.4281	0.42677
PsigMF	-0.00000091307	0.427	0.42591
TrapMF	-0.0000006336	0.4286	0.42734
TriMF	-0.00000087251	0.4729	0.47148

PiMF tiene la mejor media e histograma del error mientras que PsigMF y DsigMf presentan la menor desviación y error de entrenamiento.



La validación con 4 variables se observa a continuación. En la Tabla 3-34 se observa que GbellMF tiene la media muy próxima a cero. TrapMF tiene la menor desviación estándar.

Tabla 3-34. Análisis de funciones de membresía en fase validación con 4 variables

Funciones de membresía	Media	Desviación estándar
DsigMF	-3.7233	19.6432
GaussMF	-1.5154	8.5432
Gauss2MF	-3.2429	18.2951
GbellMF	-0.0663	12.4446
PiMF	-1.9214	10.4730
PsigMF	-3.7233	19.6432
TrapMF	-0.7171	5.0415
TriMF	-0.2925	6.8032

TrapMF es la función de membresía escogida para la modelación con 4 variables.

A continuación se presenta los mejores modelos para cada número de variables desde 7 hasta 4 que es el valor mínimo de entradas. La Tabla 3-35 presenta los valores de media y desviación para las etapas de entrenamiento y validación de los modelos seleccionados.

Tabla 3-35. Comparación de las funciones de pertenencia

#Variables	Función de membresía	Etapas	Media	Desviación estándar
7	GbellMF	Entrenamiento	3,5048E-06	0,000070941
		Validación	-1,1754	5,5466
6	GaussMF	Entrenamiento	-6,2178E-06	0,0696
		Validación	1,0097	17,3944
5	TrapMF	Entrenamiento	4,6344E-06	0,2916
		Validación	3,2657	8,3539
4	TrapMF	Entrenamiento	-6,336E-07	0,4286
		Validación	-0,7171	5,0415

El modelo seleccionado es el correspondiente al conformado por las 4 variables de entrada por defecto. La función de membresía es TrapMF. A continuación se presenta el análisis de acuerdo al número de iteraciones, el modelo actual es de 10 iteraciones.

Tabla 3-36. Comparación de las funciones de pertenencia

Número de iteraciones	Media	Desviación estándar
100	-0.8376	4.9427
200	-0.6675	6.7734
300	-0.5934	5.7539
400	-0.5934	5.7539

La función con 100 iteraciones presenta una mejor desviación con respecto de la de 10, por lo que será la que modele la fineza de retenido. La Figura 3-62 muestra la predicción del modelo total.




Figura 3-62. Estimación del modelo de predicción final del retenido de malla sin corrección

Los valores de media y desviación estándar para la estimación final del modelo de retenido de malla son:

$$\mu = -0.1675; \quad \sigma = 2.2462$$

El modelo obtenido posee valores que se encuentran fuera de los límites de la variable de calidad. En el capítulo 4 en la sección de corrección de modelos se estimará el modelo definitivo. La Figura 3-63 muestra la arquitectura del modelo neurodifuso implementado.

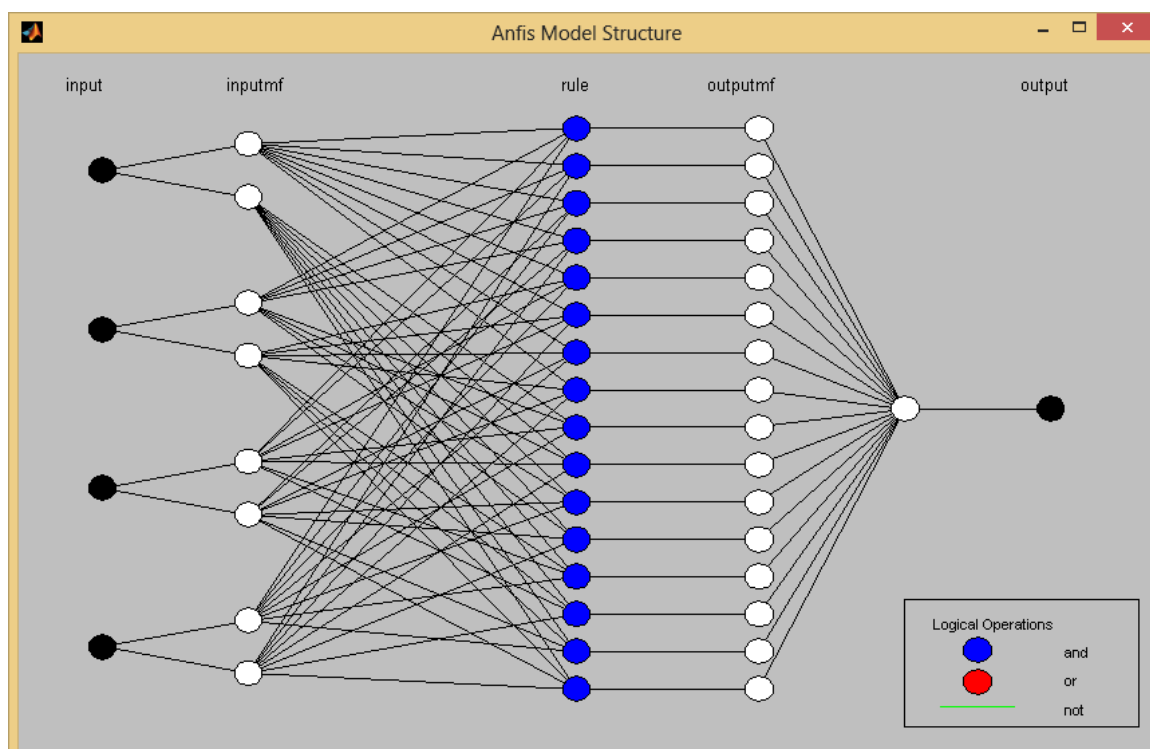


Figura 3-63. Arquitectura del modelo neurodifuso para el retenido de malla



Capítulo 4: VALIDACIÓN DE LOS MODELOS DESARROLLADOS

4.1 Introducción

183

En este capítulo se realiza la aprobación de los modelos obtenidos para las variables de calidad: Blaine y retenido de malla de 45 μm .

Los cuatro modelos desarrollados: estadístico, autorregresivo, neuronal y neurodifuso, son comparados en su capacidad de predicción con valores recolectados mediante el sistema SCADA de la planta UCEM. El criterio de comparación utilizado es el análisis de los residuos; se contrastan las distribuciones del error y se calculan los errores cuadráticos medios.

Se determina el mejor modelo para cada variable de calidad y se procede a las pruebas y validación en la planta de cemento.

4.2 Aprobación de los modelos con nuevo set de datos

En esta sección se comprueba la capacidad de predicción para nuevos datos de los modelos obtenidos. Los datos disponibles con este propósito son del mes de enero del 2015.

Los datos de las variables de proceso, provienen de la base de datos del sistema SCADA del circuito de molienda de cemento. Los datos se adquieren con un periodo de muestreo de un minuto.

Las variables de calidad, Blaine y fineza de retenido de malla No. 325, se obtienen de las anotaciones de los panelistas (cada dos horas) en el control de calidad.

Para el desarrollo de la validación, se alinean los datos de proceso y los datos de calidad. Antes, se procede a decimar los datos de las variables de proceso, aumentando el periodo de muestreo a cinco minutos. Se disponen, por tanto, por cada periodo de muestreo de las variables de calidad, veinte y cuatro periodos de muestreo de las variables de proceso, debido a que se realizan pruebas de laboratorio cada 2 horas para las variables de calidad.

Inicialmente se simula el comportamiento de las variables de operación junto a las variables de calidad, herramienta que se utilizará para comprobar los modelos desarrollados.

La comprobación de los modelos de fineza se realiza a través de la evaluación de éstos con datos de proceso. El tiempo de muestreo utilizado para los modelos es de cinco minutos. El rendimiento del modelo se valora de acuerdo al ajuste en la predicción de los datos experimentales obtenidos cada dos horas.

4.2.1 Variables de proceso

La Figura 4-1 muestra la lectura de valores de la base de datos de la planta, correspondiente a las variables utilizadas para el Blaine.

La Figura 4-2 muestra la lectura de valores de la base de datos de la planta, correspondiente a las variables utilizadas para el retenido de malla No. 325

Se observa que existen interrupciones en la operación de algunas variables de proceso por periodos considerables de tiempo. Estas simulaciones se utilizarán en la validación y ajuste de los modelos desarrollados.

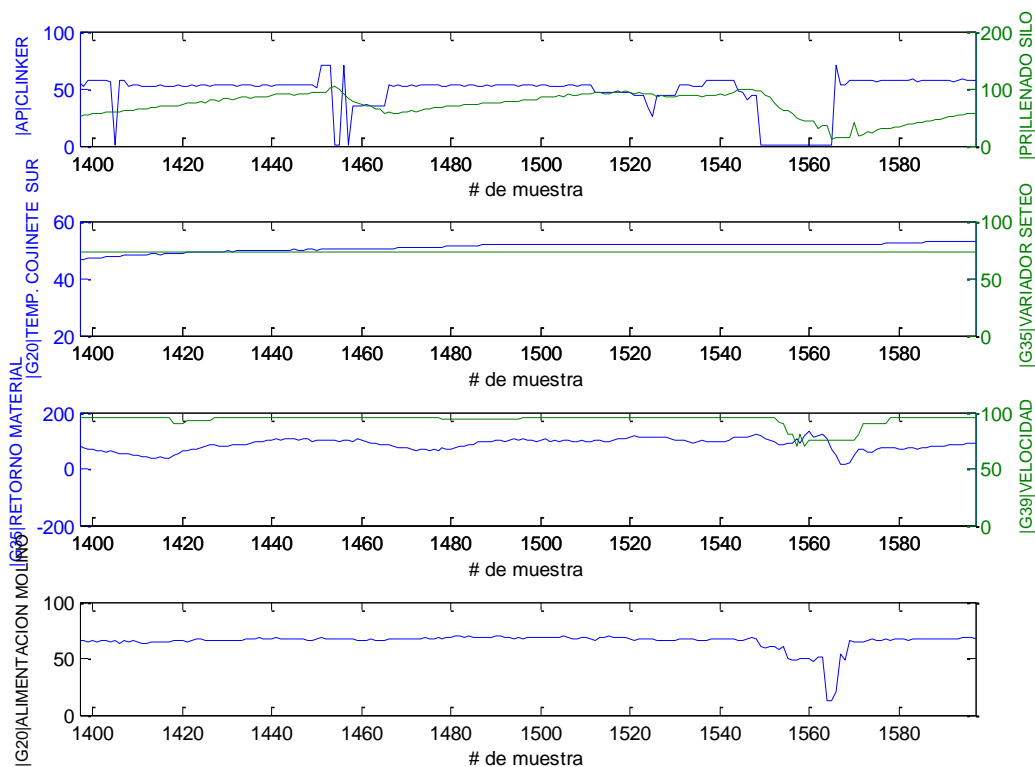


Figura 4-1. Variables de proceso para la evaluación del modelo del Blaine




Figura 4-2. Variables de proceso para la evaluación del modelo de retenido de malla

4.2.2 Aprobación de los modelos estadísticos

Los modelos estadísticos que se comprueban son: Modelo de regresión lineal múltiple de segundo orden y modelo de regresión lineal múltiple con transformación Box-Cox de la variable de calidad. El proceso de validación que se plantea es el siguiente:

Paso 1. Identificación de las variables de proceso que requiere el modelo de la variable de calidad.

Paso 2. Estandarización de los datos de proceso. La estandarización es por cada muestra que ingresa a la comprobación; se requiere corregir la media y la varianza en cada etapa de comprobación. Esta corrección se realiza de acuerdo a las siguientes formulaciones.

Corrección de la media: La media utilizada en la estandarización de una nueva muestra es:

$$\mu_n = (N_m * u_m + x_n) \frac{1}{1 + N_m} \quad (4-1)$$

donde μ_n es la media corregida, N_m y μ_m son el número de muestras y la media encontradas en el proceso de modelación y x_n es la nueva muestra utilizada en la comprobación.

Corrección de la desviación estándar: La desviación estándar utilizada en la tipificación de una nueva muestra es:

$$\sigma_n = \left(\frac{N_m * \sigma_m^2 + N_m * u_m^2 + x_n^2 - (N_m + 1) * \mu_n^2}{N_m + 1} \right)^{1/2} \quad (4-2)$$

donde σ_n y μ_n son la media y la desviación estándar corregidas, σ_m , u_m y N_m son la media, desviación estándar y número de muestras utilizadas durante la modelación y x_n es la nueva muestra.



Paso 3. Evaluación del modelo con los nuevos datos de proceso estandarizados. Se procede a determinar la variable de calidad que predice el modelo. En el caso del modelo que incluye la transformación no lineal de la variable de calidad se obtiene la transformada Box-Cox inversa para la comparación con los datos anotados.

Paso 4. Evaluación de resultados sobre la comparación de los datos de calidad encontrados con los datos anotados. La evaluación se enfoca en determinar la exactitud de las predicciones y la capacidad de predicción de la tendencia de respuesta en el tiempo de la variable de calidad.

4.2.2.1 Aprobación del modelo de regresión de segundo orden del Blaine

Para el modelo de regresión lineal múltiple de segundo orden del Blaine representado por la ecuación (3-4) se obtienen los resultados mostrados en la Figura 4-3. Adicionalmente se muestra el comportamiento de las variables de regresión que se incluyeron por defecto en la modelación (sección 3.3.1).

Se observa que las predicciones del modelo son aproximadas a los valores reales, además las tendencias son pronosticadas correctamente en su mayoría.

En la Figura 4-4 se indica el histograma y la gráfica de probabilidad normal del error obtenida para este modelo. A continuación, se presentan los valores correspondientes a la media del error y desviación estándar.

$$\mu = -34.39 ; \quad \sigma = 217.8$$

Estos datos indican que el modelo de predicción no es muy adecuado en la predicción del Blaine.




Figura 4-3. Validación del modelo de regresión lineal múltiple de segundo orden del Blaine con corrección de la media y desviación estándar




Figura 4-4. Histograma y gráfico de probabilidad normal del error de validación del modelo de segundo orden del Blaine

4.2.2.2 Aprobación del modelo de regresión de segundo orden con transformación Box-Cox del Blaine

Para el modelo estadístico con transformación Box-Cox del Blaine representado por la ecuación (3-6), y su transformación inversa dada por la ecuación (3-7), se obtienen los resultados mostrados en la Figura 4-5. Además se observa el comportamiento de las variables de regresión que se incluyeron por defecto en la modelación (sección 3.3.1).

De acuerdo a la Figura 4-5, la respuesta es similar a las predicciones del modelo largo de segundo orden; los valores determinados por el modelo son aproximados a los valores medidos y la tendencia en su mayoría son correctamente pronosticados.




Figura 4-5. Validación del modelo de regresión lineal múltiple con transformación Box-Cox del Blaine y corrección de la media y desviación estándar

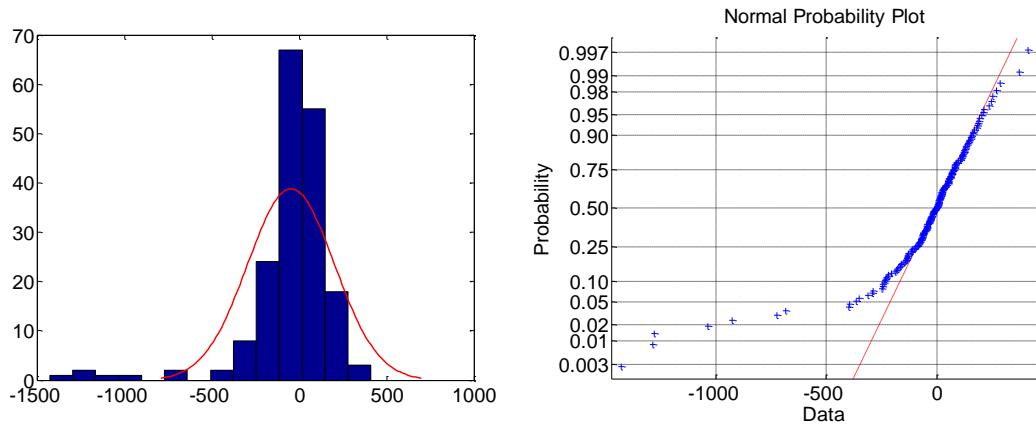


Figura 4-6. Histograma y gráfico de probabilidad normal del error de validación del modelo con transformación Box-Cox del Blaine

En la Figura 4-6, se muestran el histograma y la gráfica de probabilidad normal del error del modelo. A continuación, se presentan los valores correspondientes a la media del error y desviación estándar.

$$\mu = -46.5349; \quad \sigma = 248.177$$

Lo que indica que su capacidad de predicción es menor que el modelo de segundo orden.

4.2.2.3 Aprobación del modelo de regresión de segundo orden del retenido de malla No. 325

El modelo largo de segundo orden del retenido de malla No. 325, representado por la ecuación (3-10), genera los resultados que se muestran en la Figura 4-7. También se muestra el comportamiento de las variables de regresión que se incluyeron por defecto en la modelación (sección 3.3.1).

Según la Figura 4-7, las predicciones no son muy aproximadas a los datos reales, sin embargo en su mayor parte las tendencias son determinadas correctamente. En la Figura 4-8 se indica el histograma del error y la gráfica de probabilidad normal del error del modelo. A continuación, se presentan los valores correspondientes a la media del error y desviación estándar.

$$\mu = -0.2062; \quad \sigma = 1.4894$$



Lo que indica que el modelo es adecuado para la predicción el retenido de malla.




Figura 4-7. Validación del modelo de regresión lineal múltiple de segundo orden del retenido de malla No. 325 con corrección de la media y desviación estándar




Figura 4-8. Histograma y gráfico de probabilidad normal del error de validación del modelo de segundo orden del retenido de malla

4.2.2.4 Aprobación del modelo de regresión de segundo orden con transformación Box-Cox del retenido de malla No. 325

El modelo con transformación Box-Cox del retenido de malla No. 325, representado por la ecuación (3-12), y su transformación inversa dada por la ecuación (3-13) , genera los resultados que se muestran en la Figura 4-9. Se muestra también las variables que se incluyeron por defecto en la modelación (sección 3.3.1).




Figura 4-9. Validación del modelo de regresión lineal múltiple con transformación Box-Cox del retenido de malla No. 325 y corrección de la media y desviación estándar

De acuerdo a la Figura 4-9, las predicciones son aproximadas a los datos reales. Las tendencias son determinadas en su mayoría de forma correcta.




Figura 4-10. Histograma y gráfico de probabilidad normal del error de validación del modelo con transformación Box-Cox del retenido de malla

En la Figura 4-10 se muestra el histograma y el gráfico de probabilidad normal del error del modelo. A continuación, se presentan los valores correspondientes a la media del error y desviación estándar.

$$\mu = -0.2913; \quad \sigma = 1.3211$$

Estos resultados indican que el modelo de predicción con transformación Box-Cox del retenido de malla tiene menor capacidad de predicción que el modelo de segundo orden.

4.2.3 Aprobación de los modelos dinámicos

El procedimiento de aprobación de los modelos dinámicos autorregresivos se desarrolla de la misma forma que en los modelos estadísticos.

4.2.3.1 Aprobación del modelo autorregresivo del Blaine

El modelo autorregresivo del Blaine expresado por la ecuación (3-15) genera los resultados mostrados en la Figura 4-11. Se muestra también las variables de regresión que se utilizaron por defecto en la modelación (sección 3.3.1). El modelo genera resultados muy aproximados en las predicciones, además el seguimiento en las tendencias se observan correctas en su mayoría.




Figura 4-11. Validación del modelo autorregresivo del Blaine con corrección de la media y desviación estándar




Figura 4-12. Histograma y gráfico de probabilidad normal del error de validación del modelo autorregresivo del Blaine

En la Figura 4-12 se observa el histograma y gráfico de probabilidad normal del error del modelo. A continuación, se presentan los valores correspondientes a la media del error y desviación estándar.

$$\mu = -15.1542 ; \quad \sigma = 173.0151$$

Estos resultados muestran que el modelo autorregresivo proporciona mejores predicciones del Blaine que los modelos estadísticos.

4.2.3.2 Aprobación del modelo autorregresivo del retenido de malla No. 325

El modelo autorregresivo del retenido de malla No. 325 expresado por la ecuación (3-17) produce los resultados mostrados en la Figura 4-13. Adicionalmente se observan el comportamiento de las variables de regresión utilizadas por defecto en la modelación (sección 3.3.1).




Figura 4-13. Validación del modelo autorregresivo del retenido de malla No. 325 con corrección de la media y desviación estándar




Figura 4-14. Histograma y gráfico de probabilidad normal del error de validación del modelo autorregresivo del retenido de malla

De acuerdo a la Figura 4-13, las predicciones del modelo en su mayoría son correctas, como también las tendencias pronosticadas. En la Figura 4-14 se muestra el histograma y gráfico de probabilidad normal del error del modelo. A continuación, se presentan los valores correspondientes a la media del error y desviación estándar.

$$\mu = -0.4214 ; \quad \sigma = 1.0896$$

Estos resultados indican una mayor capacidad de predicción de retenido de malla del modelo autorregresivo frente a los modelos estadísticos.

4.2.4 Aprobación de los modelos neuronales

La aprobación de los modelos para las variables de calidad correspondientes al Blaine y al retenido de malla No. 325 se realiza con el set de datos correspondiente al mes de enero del 2015, del sistema SCADA.

4.2.4.1 Aprobación del modelo neuronal del Blaine

El modelo neuronal del Blaine es representado por la ecuación (3-6). La Figura 4-15 presenta la estimación del modelo del Blaine con el set de datos correspondiente al mes de enero. Además se observa el comportamiento de las variables de regresión que se incluyeron por defecto en la modelación (sección 3.3.1).




Figura 4-15. Validación del modelo neuronal del Blaine




Figura 4-16. Histograma y gráfico de probabilidad normal del error de validación del modelo neuronal del Blaine

Los resultados obtenidos en la predicción son pobres en su totalidad. La Figura 4-16 muestra el histograma y gráfico de probabilidad normal del error de predicción del modelo. La media del error es 1.6409 y la desviación estándar de 255.4515. Los valores experimentales varían mucho respecto de los de predicción. En la sección 4.3.3 se realizará la corrección del modelo y se observará la estimación definitiva.

4.2.4.2 Aprobación del modelo neuronal del retenido de malla de 45 μm

El modelo neuronal del retenido de malla es representado por la ecuación (3-6). La Figura 4-17 presenta la estimación del modelo del Blaine con el set de datos correspondiente al mes de enero. Además se observa el comportamiento de las variables de regresión que se incluyeron por defecto en la modelación (sección 3.3.1).




Figura 4-17. Validación del modelo neuronal del retenido de malla




Figura 4-18. Histograma y gráfico de probabilidad normal del error de validación del modelo neuronal del retenido de malla

La Figura 4-18 muestra el histograma y gráfico de probabilidad normal del error de predicción del modelo. La media del error es -0.2003 y la desviación estándar es 1.0681. El modelo estimado sigue el comportamiento real de la planta en su gran mayoría. En la sección 4.3.3 se realiza la corrección del modelo para obtener el definitivo.

4.2.5 Aprobación de los modelos neurodifusos

La aprobación de los modelos neurodifusos se realiza con el mismo set de datos que los tres modelos anteriores. A continuación se presenta la aprobación de los modelos para el Blaine y retenido de malla.

4.2.5.1 Aprobación del modelo neurodifuso del Blaine

En la etapa de validación del modelo neurodifuso para el Blaine se utilizó un set diferente de datos a los de entrenamiento, sin embargo se realiza la aprobación con los datos utilizados en los modelos anteriores, ya que permitirá realizar la comparación entre los modelos y elegir el mejor de los propuestos.

La Figura 4-19 muestra la estimación del modelo neurodifuso con los datos correspondientes al mes de enero. Además se observa el comportamiento de las variables de regresión que se incluyeron por defecto en la modelación (sección 3.3.1).




Figura 4-19. Validación del modelo neurodifuso del Blaine




Figura 4-20. Histograma y gráfico de probabilidad normal del error de validación del modelo neurodifuso del Blaine



La Figura 4-20 muestra el histograma y gráfico de probabilidad normal del error de predicción del modelo. La media del error es -25.9511 y la desviación estándar es 437.7198. Los resultados indican que el modelo no es adecuado en la predicción del Blaine. Se observa también (Figura 4-19) que los resultados de predicción toman valores que salen de los márgenes de los valores máximo y mínimo estudiados en la sección de análisis estadístico de las variables de calidad. Estos valores por tanto no son posibles en el comportamiento real de la planta. La corrección del modelo se realiza en la sección 4.3.4.

4.2.5.2 Aprobación del modelo neurodifuso del retenido de malla de 45 μm

De la misma forma se realiza la aprobación para el modelo de retenido de malla. La Figura 4-21 muestra la estimación del modelo neurodifuso con los datos correspondientes al mes de enero. Además se observa el comportamiento de las variables de regresión que se incluyeron por defecto en la modelación (sección 3.3.1).




Figura 4-21. Validación del modelo neurodifuso del retenido de malla de 45 μm




Figura 4-22. Histograma y gráfico de probabilidad normal del error de validación del modelo neurodifuso del retenido de malla

La Figura 4-22 muestra el histograma y gráfico de probabilidad del error de predicción del modelo. La media del error es -0.2086 y la desviación estándar es 1.4559. Las predicciones obtenidas coinciden en gran medida con los datos experimentales a pesar de que se trata de un modelo no corregido. La corrección del modelo se presenta en la sección 4.3.4.

4.3 Corrección de los modelos

En esta sección se realiza la corrección de los modelos desarrollados para lograr un mejor rendimiento en sus predicciones.

En base a las validaciones realizadas en la sección anterior, se adaptan los modelos y generan nuevas estimaciones.

4.3.1 Corrección de los modelos estadísticos

Para mejorar la respuesta de los modelos estadísticos se plantea un filtrado de las predicciones generadas por el modelo. Los filtros propuestos son de promedio móvil, con ventanas de longitud fija los cuáles se determinan en función de la mejor predicción generada.



Los modelos estadísticos de segundo orden generan los mejores resultados de validación para ambas variables de calidad. Por ello, los modelos considerados en la corrección son únicamente los modelos largos de segundo orden para el Blaine y el retenido de malla No. 325.

El mejor resultado encontrado es para el filtro con longitud de ventana de 5 predicciones, con error de predicción de media 23.084 y desviación estándar 209.45. Por tanto, el modelo estadístico para el Blaine seleccionado, para comparar las demás técnicas de modelación desarrolladas en este trabajo, es el de segundo orden con filtro promedio de ventana fija de cinco predicciones.

De igual forma, para el modelo del retenido de malla No. 325 se utilizará el modelo de segundo orden con filtro de promedio móvil de ventana fija de cinco predicciones, cuyo error de predicción tiene una media de 0.24448 y desviación estándar de 0.88742.




Figura 4-23. Respuesta del modelo corregido de regresión lineal múltiple del Blaine




Figura 4-24. Respuesta del modelo corregido de regresión lineal múltiple del retenido de malla No. 325

En la Figura 4-23 se muestran las predicciones encontradas para el Blaine con el filtro promedio con longitud de ventana de cinco muestras. La Figura 4-24 muestra las predicciones del modelo de segundo orden corregido del retenido de malla de 45 μm .

Las respuestas de los modelos estadísticos son satisfactorias. El sistema no es lineal y tiene mucha incertidumbre, pese a ello, los modelos estadísticos de regresión lineal múltiple encontrados son capaces de predecir en forma muy aproximada los datos de calidad.

4.3.2 Corrección de los modelos dinámicos

Los modelos autorregresivos encontrados, permiten añadir a su ecuación valores pasados de la variable de calidad modelada. Esta característica se propone utilizar en la corrección de los modelos dinámicos.



En la validación realizada con los datos de enero del 2015, los retrasos de la variable de calidad son tomados de las respuestas generadas por el mismo modelo. Sin embargo, debido a que se disponen de datos de calidad con periodos de muestreo de dos horas, éstos pueden utilizarse en la corrección del modelo si se incluyen en la ecuación como los retrasos requeridos.

Los resultados de la corrección son: el error en la predicción del Blaine tiene una media de -7.5016 y desviación estándar de 203.2395. El error de predicción del retenido de malla tiene una media de 0.42579 y una desviación estándar de 0.92459.

Los resultados de la corrección para el modelo autorregresivo del Blaine se muestran en la Figura 4-25, y para el de retenido de malla No. 325 en la Figura 4-26.




Figura 4-25. Respuesta del modelo autorregresivo corregido del Blaine




Figura 4-26. Respuesta del modelo corregido autorregresivo del retenido de malla No. 325

El ajuste realizado proporciona mejores resultados en ambos casos.

4.3.3 Corrección de los modelos neuronales

La corrección en los modelos neuronales se realiza de la misma manera que los modelos estadísticos, es decir, mediante un filtro promedio con ventaja fija de cinco predicciones.

Los resultados de corrección son: en la predicción del Blaine el error es de media -19.566 y desviación estándar 223.997, y en la predicción del retenido de malla el error es de media 0.31892 y desviación estándar 0.91035.

Los modelos corregidos para el Blaine y el retenido de malla se observan en la Figura 4-27 y la Figura 4-28.




Figura 4-27. Corrección del modelo neuronal del Blaine

Los resultados obtenidos con el filtro eliminan el ruido y los cambios bruscos en el modelo por lo cual mejora la predicción, sin embargo los resultados son similares a los que se obtuvieron en la aprobación de los modelos.




Figura 4-28. Corrección del modelo neuronal de la fineza de retenido de malla

4.3.4 Corrección de los modelos neurodifusos

La corrección se realiza ajustando los resultados de predicción que resultan fuera del intervalo normal para las variables de calidad. Para el Blaine el intervalo es desde 3900 a 4300 cm^2/g y para el retenido de malla el intervalo es desde 3 a 5 % (Tabla 3-3).

Los resultados de corrección son: en la predicción del Blaine el error es de media -8.5363 y desviación estándar 198.032, y en la predicción del retenido de malla el error es de media 0.35789 y desviación estándar 0.86904.

La Figura 4-29 muestra los resultados de la corrección para el modelo del Blaine, y la Figura 4-30, para el modelo del retenido de malla de 45 μm .




Figura 4-29. Corrección del modelo neurodifuso del Blaine




Figura 4-30. Corrección del modelo neurodifuso del retenido de malla de 45 μm

Los modelos corregidos mejoran notablemente los valores de predicción para las variables de calidad, sobre todo en el caso del retenido de malla. Los resultados son satisfactorios.

4.4 Selección de los modelos de predicción

Para el proceso de selección de los mejores modelos de predicción de las variables de calidad, los modelos corregidos se comparan mediante el estudio de los residuos.

Un criterio adicional que se utiliza es la raíz del error cuadrático medio.

4.4.1 Selección del mejor modelo de predicción para el Blaine

La Figura 4-31 muestra las predicciones de los cuatro modelos para el Blaine.




Figura 4-31. Predicciones de los modelos del Blaine

En la Figura 4-32 se muestra el comportamiento de los histogramas del error, de los modelos, cuyos estadísticos descriptivos se muestran en la Tabla 4-1. Además, en esta tabla, se muestra el cálculo de la raíz del error cuadrático medio para cada técnica de modelación.

El modelo de Blaine que proporciona los mejores resultados es el neurodifuso.

Tabla 4-1. Comparación de los modelos del Blaine

Técnica de modelación	Error		Raíz del Error cuadrático medio
	Media	Desviación estándar	
Estadística	23.084	209.4595	210.1673
Autorregresiva	-7.5016	203.2395	202.8312
Neuronal	-19.566	223.9997	224.2519
Neurodifusa	-8.5363	198.032	197.6833

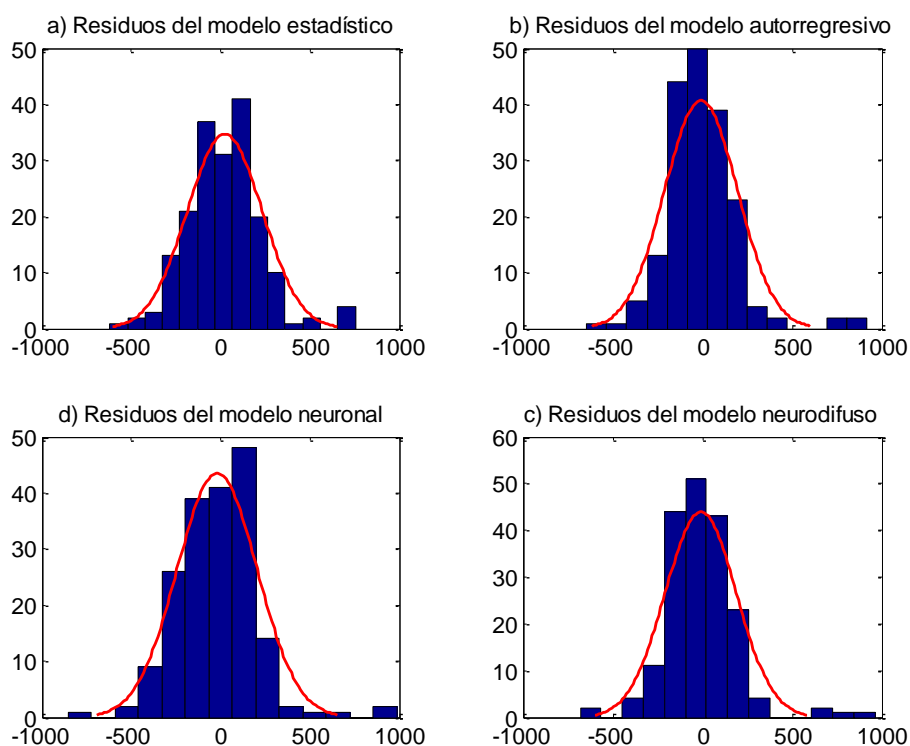


Figura 4-32. Histogramas de error de los modelos del Blaine

4.4.2 Selección del mejor modelo de predicción para el retenido de malla de 45 μm

La Figura 4-33 muestra las predicciones de los cuatro modelos para el retenido de malla de 45 μm .

En la Figura 4-34 se muestra el comportamiento de los histogramas del error, cuyos estadísticos descriptivos se muestran en la Tabla 4-2. Además, en esta tabla, se muestra el cálculo del error cuadrático medio para cada técnica de modelación.

El modelo del retenido de malla de 45 μm que proporciona los mejores resultados es el neurodifuso.




Figura 4-33. Predicciones de los modelos del retenido de malla de 45 μm

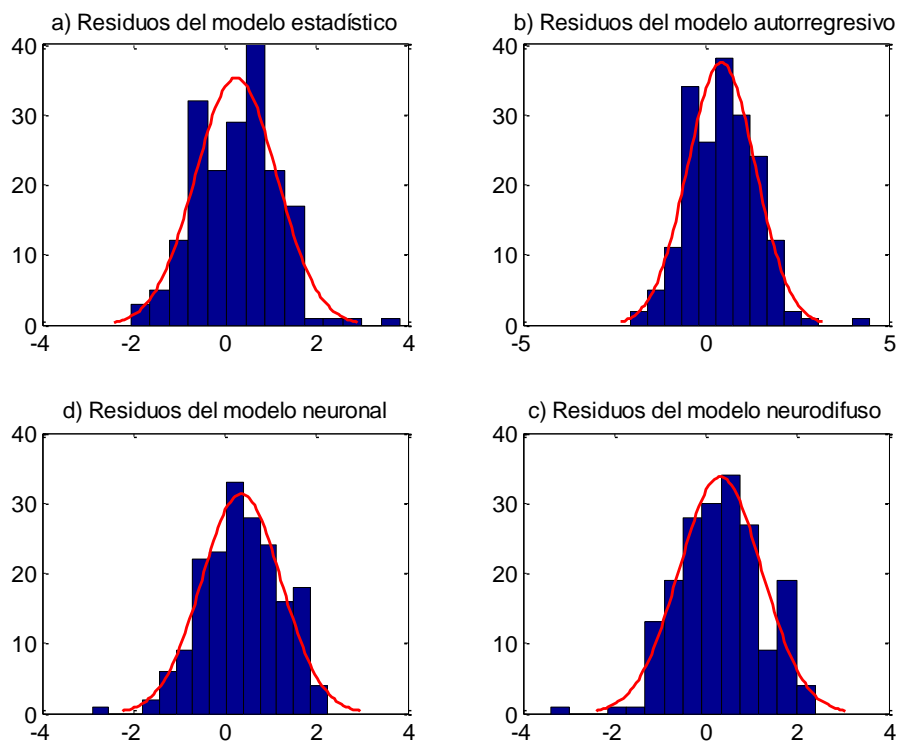


Figura 4-34 Histogramas de error de los modelos del retenido de malla

Tabla 4-2. Comparación de los modelos del retenido de malla de 45 μm .

Técnica de modelación	Error		Raíz del error cuadrático medio
	Media	Desviación estándar	
Estadística	0.24448	0.88742	0.91818
Autorregresiva	0.42579	0.92459	1.0157
Neuronal	0.31892	0.91035	0.96228
Neurodifusa	0.35789	0.86904	0.93769

4.5 Resultados experimentales

Los modelos obtenidos para las variables de calidad, se validan en la planta de cemento UCEM, Guapán. En dos turnos de operación diferentes, en días diferentes, se tomaron muestras de las variables de operación cada diez minutos. El software de predicción que se observa en la Figura 4-35, fue desarrollado en LabVIEW y contiene los modelos con mejores resultados para Blaine y retenido de malla. Luego de la validación, se entregó una aplicación ejecutable con los modelos de predicción al departamento de investigación y desarrollo de UCEM, Guapán.

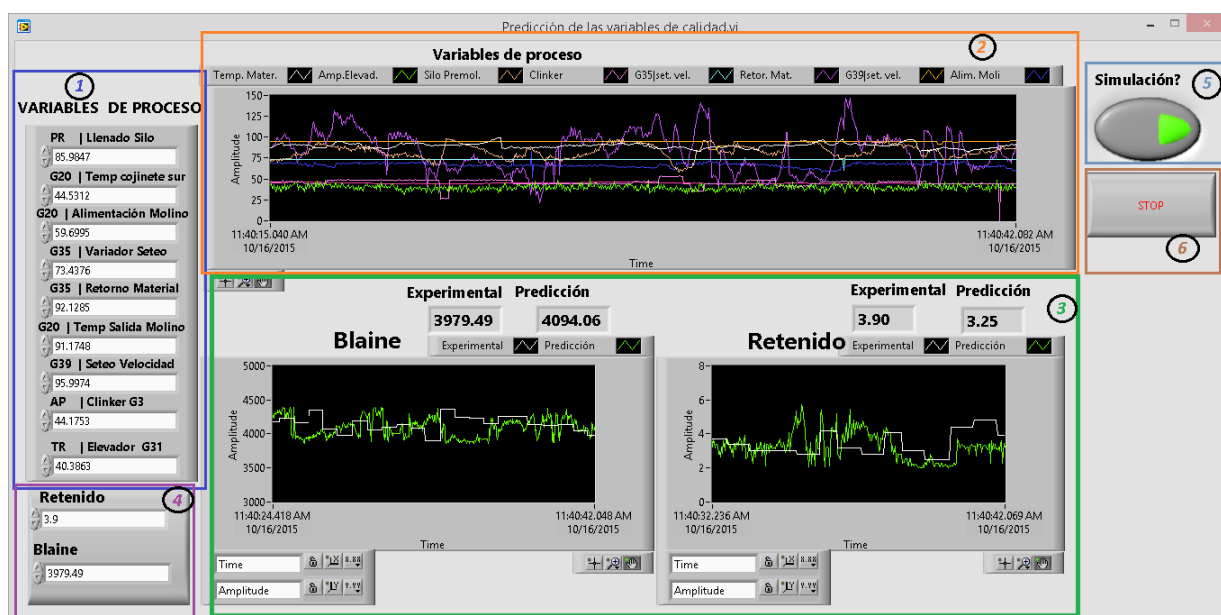


Figura 4-35. Software de predicción de las variables de calidad

La Figura 4-35 presenta la interfaz del software de predicción, el cual se encuentra dividido en los siguientes bloques:



1. Ingreso de las variables de proceso: Las variables utilizadas son:

- Llenado de silo en premolienda (%),
- Temperatura del cojinete sur del molino G20 (°C),
- Alimentación del Molino G20 (tph),
- Consigna de velocidad del separador G35 (%),
- Retorno del material (tph),
- Temperatura de salida del Molino (°C),
- Consigna de velocidad del G39 (%),
- Alimentación de Clinker (tph),
- Amperaje del elevador G31 (A).

2. Visualización de las variables de proceso

3. Visualización de las variables de calidad: Se muestran gráficas e indicadores para el Blaine y el retenido, de los datos de predicción y de operación.

4. Ingreso de las variables de calidad: Las variables utilizadas son:

- Blaine (cm^2/g),
- Retenido de malla (%)

5. Control de simulación: Tiene dos funcionalidades que se describen a continuación:

- Simulación: Genera los resultados de predicción y operación correspondientes a la base de datos de sistema SCADA.
- Predicción: Permite el ingreso de datos de operación para generar las predicciones de Blaine y retenido de malla.

6. Control de parada: Detiene la ejecución del programa.

4.5.1 Resultados experimentales del mejor modelo de predicción para el Blaine

La Figura 4-36 muestra las predicciones del modelo del Blaine en contraste con los valores experimentales.




Figura 4-36. Predicción del Blaine con datos de operación en la planta

La Tabla 4-3 presenta el análisis del error residual de todos los modelos con datos de operación de la planta de cemento.

Tabla 4-3. Análisis estadístico del error de los modelos con datos de operación para el Blaine

Técnica de modelación	Error	
	Media	Desviación estándar
Estadística	-171.88	205.1416
Autorregresiva	52.3314	201.3645
Neuronal	60.7111	145.2994
Neurodifusa	-139.800	415.4586

El modelo que presentó los mejores resultados con datos reales del proceso para el Blaine es el modelo neuronal. El error en la predicción del Blaine con el modelo neuronal tiene una desviación con respecto a su media de 145.2994 correspondiente al 3.2% del total.

4.5.2 Resultados experimentales del mejor modelo de predicción para la el retenido de malla de 45 μm

La Figura 4-37 muestra las predicciones del modelo del retenido de malla de 45 μm en contraste con los valores experimentales.




Figura 4-37. Predicción del retenido de malla con datos de operación en la planta

La Tabla 4-4 presenta el análisis del error residual de todos los modelos con datos de operación de la planta de cemento.

Tabla 4-4. Análisis estadístico del error de los modelos con datos de operación para el retenido de malla

Técnica de modelación	Error	
	Media	Desviación estándar
Estadística	-1.6355	1.5696
Autorregresiva	0.0749	0.7688
Neuronal	-1.0680	1.2498
Neurodifusa	-1.7232	1.1442

El modelo que presentó los mejores resultados con datos de operación del proceso para el retenido de malla es el modelo autorregresivo. El error en la predicción del retenido de malla con el modelo autorregresivo tiene una desviación con respecto a su media de 0.7688 correspondiente al 19.17% del total.



Capítulo 5: CONCLUSIONES

5.1 Limitaciones

La fabricación de cemento involucra procesos con alta incertidumbre, de modo que los modelos de predicción no siempre generan estimaciones acertadas.

Los modelos han sido desarrollados con un número determinado de muestras que se encuentran dentro de parámetros establecidos. Cada variable tiene sus propias características (máximo, mínimo, media, desviación estándar), por lo que responde bien dentro de los límites establecidos. La capacidad de generalización fuera de dichos valores es una limitante del trabajo propuesto.

Adicionalmente, si se modifica la estructura del circuito de molino se alterarán las correlaciones entre las variables que intervienen en el proceso y es posible que los modelos se invaliden.

No se conoce con exactitud el tiempo de respuesta con el que afecta cada una de las variables de operación a la calidad del producto final. El estudio realizado propone un tiempo de respuesta inmediato por lo que puede generar imprecisiones en la estimación de los modelos en comparación de valores reales.

La fase de entrenamiento de cada uno de los modelos propuestos fue desarrollada con la base de datos proporcionada por los operadores SCADA, por lo que está expuesta a errores de digitación y errores de sincronización en la toma de muestras correspondientes a las variables de operación y de calidad.

5.2 Conclusiones

La fineza del cemento se encuentra directamente relacionada con la cantidad y calidad de la materia prima, por lo que es de suma importancia una etapa previa de homogenización, lo cual permitiría introducir menor incertidumbre al circuito de molienda y por ende a los modelos realizados.

Para la selección de las variables que se incluyen en los modelos, además de utilizar los procedimientos de análisis estadísticos, es necesario conocer el proceso que se modela. Es probable que una variable de proceso explique significativamente el comportamiento de la variable de calidad, sin embargo no sea conveniente agregarla al modelo debido a que, por ejemplo, sus muestras son difíciles o costosas de capturar, el sensor se avería a cada momento o los datos están expuestos a errores.

Por otra parte, existen restricciones de variables que deben añadirse necesariamente en el proceso de modelación. Para este caso, las variables agregadas pertenecen a la etapa final de molienda debido a la constante manipulación de sus valores. Los operarios necesitan conocer el resultado, en la calidad del cemento, al consignar valores a los actuadores de la última etapa de molienda.

Los datos utilizados en la modelación deben ser significativos y representativos, es decir, las muestras deben representar en lo posible totalmente al comportamiento del sistema. El número de muestras debe ser amplio y contener todos los escenarios posibles para que el modelo sea eficiente. Para lograr este objetivo se realiza un análisis estadístico y tratamiento de datos.

Además, es importante no redundar en el proceso de entrenamiento debido a que el modelo puede sobreajustarse, y perderá su capacidad de predicción.



El sistema no es lineal y tiene mucha incertidumbre, lo cual limita la capacidad de predicción de los modelos estadísticos. Sin embargo, los modelos autorregresivos encontrados son capaces de predecir en forma muy aproximada los datos de calidad, debido a que integran en su ecuación valores pasados de predicción. Los modelos neuronales y neurodifusos tiene mayor capacidad de generalización en el modelamiento de sistemas, debido a que su estructura permite representar cualquier tipo de relación, sean o no lineales, entre entradas y salidas.

Los modelos desarrollados se denominan modelos de caja negra (black-box models), debido a que no se necesita conocer la fenomenología presente en el proceso de molino de cemento. Únicamente es necesario disponer de las entradas y salidas del sistema.

La corrección de los modelos, gracias al análisis estadístico previo, se logra a través de la eliminación de datos atípicos, correcciones de media y desviaciones estándar. Esto permite aproximar de mejor manera los valores de predicción a los reales.

5.3 Trabajo futuros

En este trabajo se ha propuesto la comparación entre varios modelos de predicción, lo cual ha permitido escoger el de mejores resultados con datos de operación. Se propone dar un alcance adicional al trabajo, a través de:

- Incluir un análisis de tiempo de respuesta para cada variable de operación y su relación con la fineza del cemento.
- Integrar la metodología desarrollada para incluir todas las variables de calidad de fineza de cemento en la planta industrial UCEM, como por ejemplo el óxido de calcio.
- Generar lazos o sistemas de control a partir de los modelos obtenidos, de manera que permita disminuir la variabilidad de calidad del producto final.



Referencias

- [1] Sacoto Flores, María Augusta, and Karla Cristina Esquivel Paladines. Aplicación de un sistema de control estadístico de procesos en las áreas de producción de cemento en Compañía Industrias Guapán SA. Diss. 2008.
- [2] ASTM C 430. "Standard test method for fineness of hydraulic cement by the 45 μ m (No. 325) sieve". *American Society for Testing and Materials*, West Conshohocken, PA, 2008.
- [3] J. L. Reyes Bahena¹, O. Genç² y J. Navarro, EFECTO DE LA CARGA CIRCULANTE DE MOLIENDA DE CEMENTOS EN LOS PARÁMETROS DEL MODELO MATEMÁTICO.
- [4] Fuerstenau, Maurice C. Principles of mineral processing. SME, 2003.
- [5] Alsop, Philip A., Hung Chen, and Herman Tseng. Cement plant operations handbook: for dry process plants. Tradeship, 2007.
- [6] Miller, F. MacGregor, and Steven H. Kosmatka, eds. Innovations in Portland cement manufacturing. Vol. 2004. Portland Cement Association, 2004.
- [7] Mejeoumov, G. G. (2007). Improved cement quality and grinding efficiency by means of closed mill circuit modeling (Doctoral dissertation, Texas A&M University).
- [8] NTE INEN 957:2009, NORMA TÉCNICA ECUATORIANA, CEMENTO

HIDRÁULICO. DETERMINACIÓN DE LA FINURA MEDIANTE EL TAMIZ DE 45 μm (No. 325). Segunda revisión.

- [9] NTE INEN 196:2009, NORMA TÉCNICA ECUATORIANA, CEMENTO HIDRÁULICO. DETERMINACIÓN DE LA FINURA MEDIANTE EL APARATO DE PERMEABILIDAD AL AIRE. Segunda revisión.

- [10] Madloul, N. A., et al. "A critical review on energy use and savings in the cement industries." *Renewable and Sustainable Energy Reviews* 15.4 (2011): 2042-2060.

- [11] Grogard, Frédéric, et al. "Robust stabilization of a nonlinear cement mill model." *IEEE Transactions on Automatic Control* 46.4 (2001): 618-623.

- [12] Magni, Lalo, Georges Bastin, and Vincent Wertz. "Multivariable nonlinear predictive control of cement mills." *IEEE transactions on control systems technology* 7.4 (1999): 502-508.

- [13] Delagrammatikas, G., and Tsimas, S. (2004). "Grinding process simulation based on Rosin-Rammler equation." *Chemical Engineering Communications*, 191, 1362-1378.

- [14] Bhatti, J., Miller, F., and Kosmatka, S. (2004). Innovations in portland cement manufacturing, CD-ROM: SP400, Portland Cement Association, Skokie, IL.

- [15] ASTM C 115. "Standard test method for fineness of portland cement by



the turbidimeter". *American Society for Testing and Materials*, West Conshohocken, PA, 2010.

- [16] ASTM C 204. "Standard test method for fineness of hydraulic cement by air permeability apparatus". *American Society for Testing and Materials*, West Conshohocken, PA, 2011.
- [17] Miller, F. MacGregor, and Steven H. Kosmatka, eds. *Innovations in Portland cement manufacturing*. Vol. 2004. Portland Cement Association, 2004.
- [18] Mizonov, V., V. Zhukov, and S. Bernotat. "Simulation of grinding: new approaches." *Ivanovo State Power Engineering University Press*, Ivanovo, Russia (1997).
- [19] Gómez Sarduy, J. R., et al. "Determining cement ball mill dosage by artificial intelligence tools aimed at reducing energy consumption and environmental impact." *Ingeniería e Investigación* 33.3 (2013): 49-54.
- [20] Argoti Arcos, Roberth Miguel, and Abraham Ismael Loja Romero. *Resintonización de los PID's, simulación y modelamiento de las bandas alimentadoras de Yeso, Puzolana Y Clinker para el molino de cemento de la CIA. Industrias Guapán*. Diss. Quito: EPN, 2014., 2014.
- [21] Benzer, Hakan. "Modeling and simulation of a fully air swept ball mill in a raw material grinding circuit." *Powder technology* 150.3 (2005): 145-154.
- [22] Benzer, H., et al. "Modelling cement grinding circuits." *Minerals engineering* 14.11 (2001): 1469-1482.

- [23] Guillén, Mauro F. *Análisis de regresión múltiple*. Vol. 4. CIS-Centro de Investigaciones Sociológicas, 2014.
- [24] Walpole, Ronald E., Raymond H. Myers, and Sharon L. Myers. *Probabilidad y estadística para ingenieros*. Pearson Educación, 1999.
- [25] Box, George EP, and David R. Cox. "An analysis of transformations." *Journal of the Royal Statistical Society. Series B (Methodological)* (1964): 211-252.
- [26] Rodríguez, M^a, and R. Mora. "Estadística informática: casos y ejemplos con el SPSS." *Publicaciones Universidad de Alicante, España* (2001).
- [27] Shacham, Mordechai, Neima Brauner, and Haim Shore. "A new procedure to identify linear and quadratic regression models based on signal-to-noise-ratio indicators." *Mathematical and computer modelling* 46.1 (2007): 235-250.
- [28] Esteban, M. Victoria, et al. "Análisis de regresión con Gretl." *Departamento de economía Aplicada III, Universidad del País Vasco* (2009).
- [29] Pineda, Gabriela López, Gladys Linares Fleites, and Hortensia Josefina Reyes Cervantes. "Análisis de Regresión para la Estimación del Secuestro de Carbono Orgánico en Suelos."
- [30] Castillo, M., et al. "Modelación de la materia orgánica en suelos volcánicos de la región de Teziutlan, Puebla, México." *Latinoamericana de Recursos Naturales. México* 5.2 (2009).



- [31] Anderson, Ronald L. "Distribution of the serial correlation coefficient." *The Annals of Mathematical Statistics* 13.1 (1942): 1-13.
- [32] Anderson, Oliver Duncan. Time series analysis and forecasting: the Box-Jenkins approach. London: Butterworths, 1976.
- [33] Box, George EP, and Gwilym M. Jenkins. *Time series analysis: forecasting and control, revised ed.* Holden-Day, 1976.
- [34] I. Viñuela, P.Galván, M. Inés, "Redes de Neuronas Artificiales: Un Enfoque Práctico", Prentice Hall. Madrid, 2004.
- [35] L. Zhang, P.B. Luh, "Neural Network-Based Market Clearing Price Prediction and Confidence Interval Estimation With an Improved Extended Kalman Filter Method", IEEE. Connecticut 2003.
- [36] Mitchel, T., "Machine Learning", McGraw-Hill, 1997
- [37] Socha, D., Ortiz, G., "APLICACIÓN DE REDES NEURONALES MLP A LA PREDICCIÓN DE UN PASO EN SERIES DE TIEMPO", Bogotá 2005.
- [38] Corral, Javier Muñiz. "PREDICCIÓN DEL PRECIO DE LA ELECTRICIDAD MEDIANTE REDES NEURONALES.", Madrid 2010.

- [39] Haykin, S., "Neural Networks: a comprehensive foundation", Macmillan 1994.
- [40] Tanaka, K., "An Introduction to Fuzzy Logic for Practical Applications", Springer 1997.
- [41] Nauck, D., "Neuro-Fuzzy Systems: Review and Prospects", 5th European Congress on Intelligent Techniques and Soft Computing 1997.
- [42] Halgamuge, S. K., Glesner, M., "Neural networks in designing fuzzy systems for real world applications", 1994.
- [43] Jang, J.S.R., Sun, C.T., "Neuro-Fuzzy Modeling and Control", 1995.
- [44] Bojórquez D., G., Bojórquez D., J., "METODOLOGIA PARA LA IMPLEMENTACIÓN DE SISTEMAS DIFUSOS TIPO MAMDANI EN LENGUAJES DE PROGRAMACIÓN DE PROPÓSITO GENERAL", México 2014.
- [45] Nauck, D., "Beyond Neuro-Fuzzy: Perspectives and Directions", Alemania 1995.
- [46] García, G., Gonzales, C., "Desarrollo de un sistema neuronal para sintonización de controladores difusos", Colombia 1997.
- [47] Jang, J.S.R., "ANFIS: Adaptative-Network-based Fuzzy Inference Systems", 1993.
- [48] Takagi, T., Sugeno, M., "Fuzzy identification of systems and its applications to modeling and control", 1985.



- [49] Lopez-Cruz, I., Hernández-Larragoiti, L., “MODELOS NEURO-DIFUSOS PARA TEMPERATURA Y HUMEDAD DEL AIRE EN INVERNADEROS TIPO CENITAL Y CAPILLA EN EL CENTRO DE MÉXICO”, México 2009.
- [50] Nedjah Nadia, Mourelle Luiza de Macedo, “*Fuzzy systems engineering – Theory and practice*”, Universidade do Estado do Rio de Janeiro, Springer, Primera edición, 2005, Holanda.